Machine Translated by Google

Revista de la Universidad de Zhejiang-SCIENCE B (Biomedicina y Biotecnología) 2024 25(10):914-940
www.jzus.zju.edu.cn; www.springer.com/journal/11585
Correo electrónico: jzus_b@zju.edu.cn

Revisar

https://doi.org/10.1631/jzus.B2400103

# Inteligencia artificial para el diagnóstico de enfermedades cerebrales mediante señales de electroencefalograma

Shunuo SHANG1,2 , Yingqian SHI1 , Yajie ZHANG1 , Mengxue LIU1 , Hong ZHANG1 , Ping WANG1,2,3*, Liujing ZHUANG1,3*

[1]Laboratorio Nacional Especial de Biosensores, Laboratorio Clave para Ingeniería Biomédica del Ministerio de Educación, Departamento de Biomedicina Ingeniería, Universidad de Zhejiang, Hangzhou 310027, China
[2]Centro de Ciencias Fronterizas para la Ciencia del Cerebro y la Integración Cerebro-Máquina del Ministerio de Educación, Universidad de Zhejiang, Hangzhou 310027, China
[3]Laboratorio Estatal Clave de Inteligencia Cerebro-Máquina, Universidad de Zhejiang, Hangzhou 310027, China

Resumen: Las señales cerebrales se refieren a señales eléctricas o cambios metabólicos que ocurren como consecuencia de la actividad de las células cerebrales. Entre los diversos métodos de medición no invasivos, el electroencefalograma (EEG) se destaca como una técnica ampliamente utilizada, Proporcionando información valiosa sobre los patrones cerebrales. Las desviaciones observadas en la lectura del EEG sirven como indicadores de actividad cerebral anormal, que está asociada con enfermedades neurológicas. Los sistemas de interfaz cerebro-computadora (BCI) permiten la extracción y transmisión directa de información del cerebro humano, lo que facilita la interacción con dispositivos externos. Cabe destacar que la aparición de la inteligencia artificial (IA) ha tenido un profundo impacto en la mejora de la precisión y exactitud en la tecnología BCI, ampliando así el alcance de la investigación en este campo. Las técnicas de IA, que abarcan modelos de aprendizaje automático (ML) y aprendizaje profundo (DL), han demostrado un éxito notable en la clasificación y predicción de varias enfermedades cerebrales. Esta revisión integral investiga la aplicación de la IA en el diagnóstico de enfermedades cerebrales basado en EEG, destacando los avances en los algoritmos de IA.

Palabras clave: Enfermedades cerebrales; Electroencefalografía; Interfaz cerebro-computadora; Inteligencia artificial

## 1 Introducción

La tecnología de interfaz cerebro-computadora (BCI) representa representa un avance significativo dentro del campo de la neurociencia y la ingeniería biomédica, ya que facilita
Establece una interfaz directa entre el cerebro humano y dispositivos externos. Esta tecnología se ha utilizado en diversos ámbitos, incluida la neurorrehabilitación (Kwak et al., 2015), la asistencia motora para discapacitados (Huang et al., 2012) y la realidad virtual (Lotte et al., 2012). Cabe destacar que La BCI tiene un inmenso potencial en el diagnóstico de enfermedades cerebrales, ofreciendo una alternativa prometedora al diagnóstico convencional. Enfoques neurológicos que con frecuencia requieren procedimientos invasivos para la recolección de biomarcadores o imágenes costosas. técnicas. Además, estos métodos se enfrentan a los obstáculos de la monitorización en tiempo real y las capacidades de detección temprana. Desde que Hans Berger logró
El primer electroencefalograma (EEG) humano se registró en 1924 y se ha convertido en una herramienta indispensable para identificar enfermedades cerebrales. Al capturar de forma continua la actividad eléctrica del cerebro, el EEG supera a otras modalidades de BCI en términos de no ser invasivo y rentable y poseer una alta resolución temporal.
La tecnología EEG puede proporcionar información detallada información sobre la función cerebral, y las variaciones en las lecturas del EEG sirven como indicadores de actividad cerebral anormal asociada con trastornos neurológicos.

Además, el diagnóstico asistido por computadora (CAD) ha surgido como una herramienta de detección potencialmente eficaz. El CAD utiliza inteligencia artificial (IA) para procesar y analizar automáticamente los datos médicos. La integración del aprendizaje automático (ML) y el aprendizaje profundo (DL)
Las odologías permiten la identificación de patologías complejas. terns dentro de los datos de entrada, mejorando la precisión y Responsabilidad de los sistemas BCI y prestación de servicios de atención sanitaria

* Liujing ZHUANG, zhuangliujing@zju.edu.cn
Ping Wang, cnpwang@zju.edu.cn
Liujing ZHUANG, https://orcid.org/0000-0001-9607-1302
Ping Wang, https://orcid.org/0000-0001-6474-2722

Recibido el 25 de febrero de 2024; Revisión aceptada el 27 de agosto de 2024;
Verificado el 23 de septiembre de 2024

© Prensa de la Universidad de Zhejiang 2024

Machine Translated by Google



profesionales con valiosos conocimientos de diagnóstico. Tecnología de IA técnicas, como la máquina de vectores de soporte (SVM), red neuronal evolutiva (CNN), red neuronal recurrente La memoria de trabajo a largo plazo (RNN) y la red de memoria a corto plazo (LSTM) se han aplicado ampliamente a los datos de EEG para detectar y predecir trastornos cerebrales.

Actualmente, se están desarrollando y perfeccionando sistemas de diagnóstico de EEG impulsados por IA para mejorar su eficacia clínica. Aplicabilidad tecnológica. Estos sistemas son capaces de realizar un seguimiento en tiempo real y una detección temprana, que son cruciales cial para una intervención y tratamiento oportunos. El profesional Los aspectos del diagnóstico EEG basados en IA son prometedores. Profundización de los algoritmos de IA y aumento de la capacidad computacional Se espera que el poder direccional mejore aún más la sensibilidad. La sensibilidad y especificidad de estas herramientas de diagnóstico. Además, es probable que el desarrollo de dispositivos EEG portátiles y ponibles integrados con tecnología de IA avance. Facilitar su aplicación generalizada en entornos clínicos y domésticos, permitiendo la monitorización continua y la monitorización personal. atención sanitaria normalizada.

En esta revisión presentamos una revisión exhaustiva Aminación de las diversas técnicas ML/DL empleadas en el diagnóstico de enfermedades cerebrales utilizando datos EEG. En concreto, investigamos siete trastornos cerebrales, a saber, epilepsia, esquizofrenia, depresión, enfermedad de Parkinson (EP), enfermedad de Alzheimer (EA), accidente cerebrovascular, y el trastorno del espectro autista (TEA).

## 2 EEG humano

### 2.1 EEG invasivo y EEG no invasivo

La adquisición de EEG se puede clasificar en técnicas invasivas y no invasivas, determinadas principalmente por la colocación de los electrodos. El EEG invasivo implica la inserción de electrodos debajo del cráneo, incluidos los intracraneales. EEG cortical (iEEG) y electrocorticograma (ECoG). iEEG captura señales de un lugar implantado específico. ción que representa un subconjunto restringido de neuronas. Por el contrario, la ECoG, aunque menos invasiva que la iEEG, Proporciona una relación señal-ruido (SNR) más alta, un ancho de banda más amplio y más información. Sin embargo, aún conlleva riesgos quirúrgicos potenciales. El EEG no invasivo recopila señales externas en el cuero cabelludo, comúnmente re- Se denomina EEG del cuero cabelludo. Esta técnica proporciona una resolución temporal alta pero una resolución espacial relativamente baja. ción. En la Fig. 1a, se representan el EEG, el iEEG y el ECoG del cuero cabelludo recopilados, cada uno originado en regiones distintas. regiones de la corteza.

### 2.2 Sistema de registro de EEG

El sistema de registro EEG emplea la colocación de electrodos en el cuero cabelludo, con la escala internacional 10-20 y los sistemas 10-10 son las configuraciones más utilizadas (Malmivuo y Plonsey, 1995). El primero divide el cuero cabelludo en intervalos del 10% y el 20%, lo que da como resultado un total de 21 ubicaciones para electrodos.

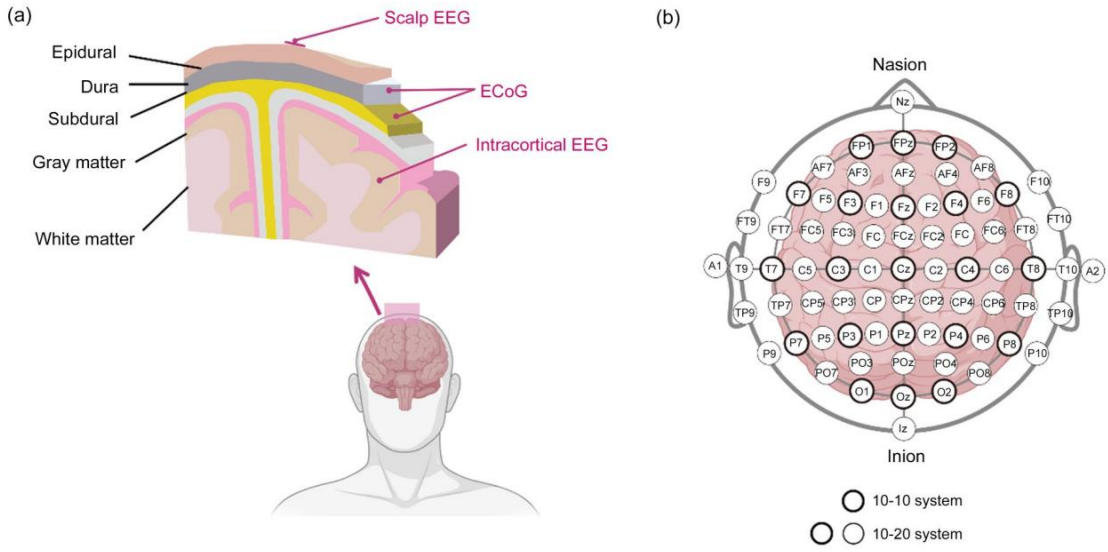


Fig. 1 Tipos de señales de electroencefalograma (EEG) y sistema de registro de EEG. (a) Ubicación de diferentes señales de EEG en relación con el cerebro. (b) Sistemas de colocación de electrodos 10-10 y 10-20. ECoG: electrocorticograma.

Machine Translated by Google



colocación, mientras que el último emplea intervalos del 10% y ofrece 75 sitios para la colocación de electrodos. Los electrodos se identifican mediante un código de letras y números que indica la posición del lóbulo, el hemisferio y el cuero cabelludo. Los números pares indican el hemisferio derecho, mientras que los números impares indican el hemisferio izquierdo. Las letras F, T,
C, P y O corresponden a los hemisferios frontal, temporal y central.
lóbulos tral, parietal y occipital, respectivamente. Un visor
La representación visual de la ubicación del electrodo se muestra en la figura 1b.

En los sistemas BCI se emplean varios tipos de electrodos, a saber, electrodos húmedos, secos y semisecos.
Electrodos húmedos, normalmente compuestos de cloruro de plata,
Se utilizan para lograr registros de EEG estables. Sin embargo, su uso requiere la aplicación
plicatura del gel, lo que conlleva inconvenientes como la producción tiempo de preparación prolongado y molestias (Ferree et al.,
2001). Por el contrario, los electrodos secos, desprovistos de conductores, El gel de silicona ofrece una aplicación más rápida y una mayor comodidad. Aunque esto puede comprometer la estabilidad de la señal, los electrodos semisecos combinan tecnologías húmedas y secas, y utilizan una cantidad mínima de gel para mejorar la conductividad sin incurrir en las desventajas asociadas con los electrodos húmedos (Mota et al., 2013).

### 2.3 Señales EEG dependientes del estado

Las señales de EEG se pueden clasificar en bandas distintas conocidas como delta (0,5–4,0 Hz), theta (4–8 Hz), alfa (8–
12 Hz), beta (12–30 Hz) y gamma (por encima de 30 Hz).
Estas bandas corresponden a diversos estados de actividad cerebral.
tividad, que abarca la vigilia y diversos patrones de sueño. Cada banda de frecuencia exhibe características y patrones únicos que están estrechamente asociados con estados de comportamiento (Roohi-Azizi et al., 2017).
Probablemente, alteraciones en la intensidad de potencia dentro de diferentes fre
Se han observado bandas de frecuencia en enfermedades neurológicas.
órdenes. En concreto, las personas con TDA-
ritmos EEG más lentos, acompañados de altura
energía aumentada en las bandas delta y theta y disminuida
energía acumulada en la banda alfa (Brenner et al., 1988).
Además, las anomalías en la banda alfa se han asociado con la fase inicial del autismo, en la que los niños con TEA muestran una energía alfa disminuida.
Indicativo de mayor ansiedad y menor relajación.
ación (Hoole et al., 2012). Los pacientes con EP carecen de emociones
Los pacientes con deterioro cognitivo leve muestran una asimetría intrahemisférica disminuida en la potencia alfa. Además,
La fiesta disminuyó la potencia general en delta, theta, alfa, y bandas beta en varios estados emocionales (Yuvaraj et al., 2014).

### 2.4 EEG espontáneo y potencial evocado

El EEG se puede dividir en EEG espontáneo y potencial evocado (PE) según la presencia o ausencia de
sentido de estimulación externa durante el proceso de medición. La utilización del EEG espontáneo como valor
La utilidad de esta herramienta en contextos científicos y clínicos, como el diagnóstico y la evaluación de la epilepsia y la EP, se ve facilitada por su capacidad para revelar el patrón de actividad neuronal inherente. Sin embargo, el EEG espontáneo muestra una relación señal-ruido baja y una variabilidad significativa entre sujetos.
lo que requiere esfuerzos adicionales en el procesamiento de datos.
La introducción de estímulos externos, como la estimulación visual o auditiva, puede inducir desviaciones específicas en las ondas cerebrales, lo que lleva a la adquisición de PE.
Las características observadas en el EP tienen el potencial de dilucidar las disparidades en la función cerebral entre los individuos.
Las señales de EP son más robustas entre los sujetos y se pueden dividir en potenciales evocados relacionados con eventos (EVP) y potenciales evocados en estado estable (SSEP).

según el modo de estímulos externos (Norcia et al.,
2015) La detección de EP ayuda en el diagnóstico y seguimiento de trastornos cerebrales como la esquizofrenia y el EA.

## 3 Inteligencia artificial

La IA ha surgido como una fuerza transformadora en el campo de la ingeniería biomédica, específicamente en el campo de la ingeniería biomédica.
Principales aspectos del diagnóstico de la enfermedad. Durante el de
En los años 80, las tecnologías de IA han mejorado significativamente el diagnóstico.
precisión cognitiva y facilitó nuevas vías para la comunicación.
Comprender trastornos cerebrales complejos. Las técnicas convencionales de ML y DL pertenecen al subcampo de la IA. ML se concentra principalmente en el desarrollo de algoritmos y modelos que permiten a las computadoras aprender y hacer predicciones o tomar decisiones sin estar programadas explícitamente (Mohri et al., 2018). SVM, lo

regresión logística (LR), árbol de decisión (DT), for
est (RF), Bayes ingenuo (NB), vecino más cercano (KNN),
análisis discriminante lineal (LDA) y otras comparaciones
Los modelos ML más utilizados se emplean con frecuencia.
En las tareas de detección de enfermedades cerebrales, la extracción de características es un paso importante que requiere la extracción manual

Machine Translated by Google



características y la realización de la selección de características. DL, una rama más sofisticada de ML, se distinguió por su capacidad para extraer, analizar y compilar automáticamente.
comprender información intrínseca a partir de datos sin procesar (LeCun et al., 2015; Schmidhuber, 2015; Goodfellow et al.,
2016). DL incluye varios tipos de clasificadores, incluidos:
ing CNN, RNN, LSTM, red de codificador automático (AEN),
y red neuronal gráfica (GNN). Los métodos ML y DL comunes para señales de EEG para detectar trastornos cerebrales
Las facilidades se pueden clasificar como se muestra en la Figura 2.
La figura 3 ilustra un sistema BCI representativo basado en IA empleado para la clasificación de señales EEG normales y anormales. La figura 4 muestra un diagrama de resumen general del diagnóstico EEG auxiliar de IA de enfermedades cerebrales.

## 4 enfoques contemporáneos de IA para el diagnóstico de enfermedades cerebrales mediante señales de EEG

### 4.1 Epilepsia

La epilepsia es un trastorno neurológico que se caracteriza por la aparición de crisis recurrentes, que pueden manifestarse en diversos síntomas como convulsiones,
pérdida de conciencia y sensaciones o movimientos atípicos.
(Krook-Magnuson y Soltesz, 2015). La prevalencia mundial de la epilepsia supera los 50 millones de personas.
también, con una tendencia al alza continua. Aunque el pre
La etiología exacta de la epilepsia sigue siendo difícil de determinar; los posibles desencadenantes incluyen traumatismos cerebrales, infecciones y factores genéticos. El impacto de la epilepsia en la calidad de vida puede incluir consecuencias como lesiones físicas, trastornos cognitivos y otras. deterioro cognitivo y aislamiento social. Por lo tanto, es necesario un diagnóstico y tratamiento oportunos y eficaces de la epilepsia.
Clínicamente, la actividad cerebral de las personas con epilepsia se puede clasificar en los siguientes cuatro estados según las lecturas del EEG: preictal, que se refiere al período inmediatamente anterior a una convulsión; ictal,
que representa el tiempo durante el cual se produce una convulsión; postictal, que denota el período posterior a una convulsión; e interictal, que corresponde al estado entre convulsiones (Jemal et al., 2021). Varios estudios enfatizan la importancia de la
El potencial de las técnicas basadas en IA para predecir las convulsiones epilépticas utilizando datos de EEG, lo que podría arrojar resultados sustanciales. avances clínicos importantes. Estos avances son
alineados en la Tabla 1.

Los métodos ML se han empleado en tareas de clasificación donde la selección de características es necesaria para identificar

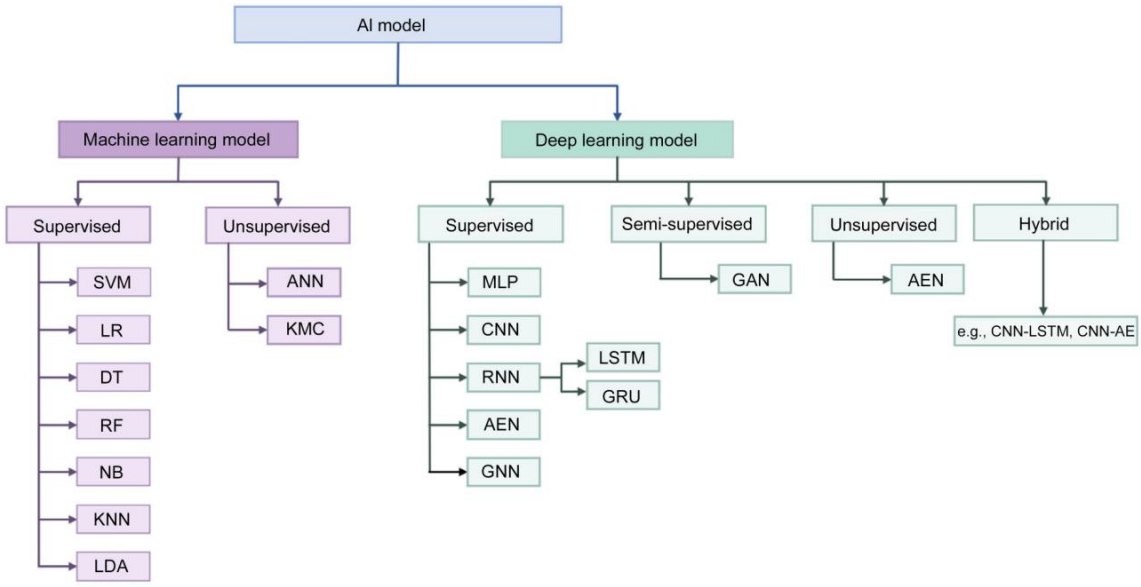


Fig. 2 Métodos comunes de aprendizaje automático (ML) y aprendizaje profundo (DL). IA: inteligencia artificial; SVM: máquina de vectores de soporte; LR: regresión logística; DT: árbol de decisión; RF: bosque aleatorio; NB: Bayes ingenuo; KNN: vecino más cercano k; LDA: análisis discriminante lineal; ANN: red neuronal artificial; KMC: agrupamiento de k-medias; MLP: perceptrón multicapa; CNN: red neuronal convolucional; RNN: red neuronal recurrente; AEN: red autocodificadora; GNN: red neuronal de grafos; LSTM: red de memoria a largo plazo y corto plazo; GRU: unidad recurrente controlada; GAN: red generativa antagónica; AE: autocodificador.

Machine Translated by Google



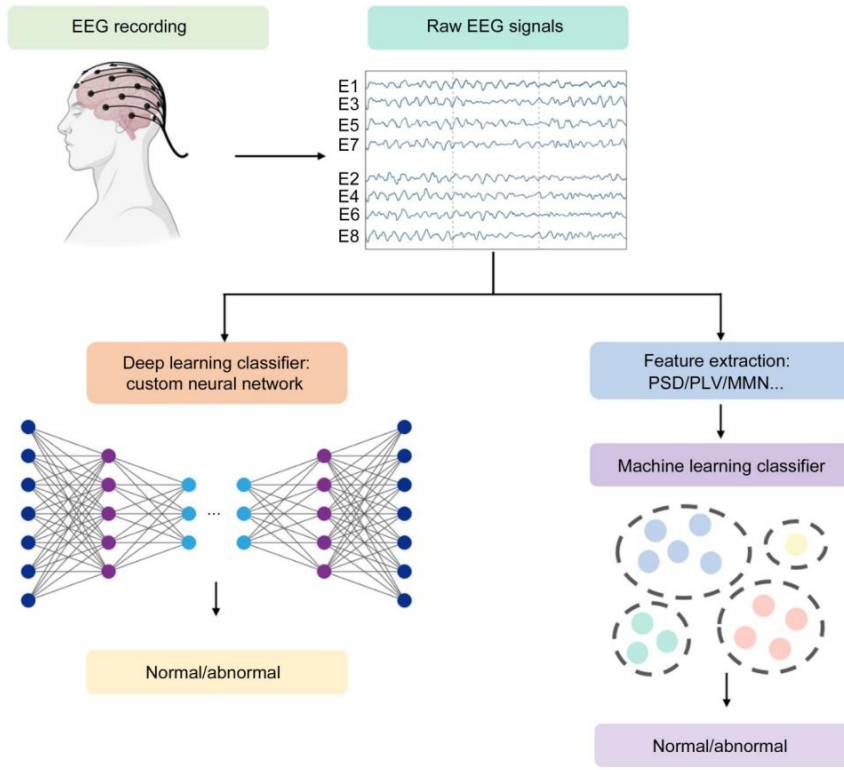


Fig. 3 Diagrama de flujo típico del diagnóstico de enfermedades basado en electroencefalograma (EEG). PSD: densidad espectral de potencia; PLV: valor bloqueado en fase; MMN: negatividad por desajuste.

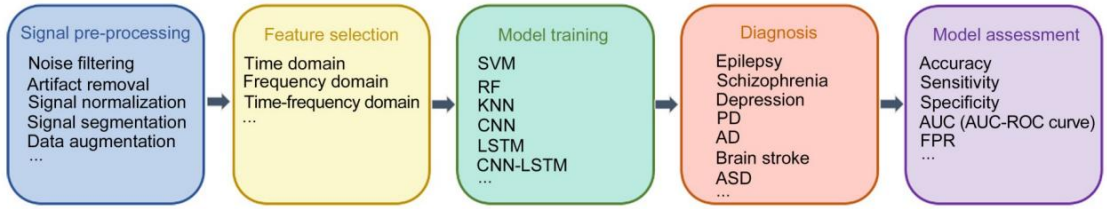


Fig. 4 Diagrama general de electroencefalograma (EEG) auxiliar de inteligencia artificial (IA) para diagnóstico de enfermedades cerebrales. SVM: máquina de vectores de soporte; RF: bosque aleatorio; KNN: vecino más cercano k; CNN: red neuronal convolucional; LSTM: red de memoria a corto y largo plazo; PD: enfermedad de Parkinson; AD: enfermedad de Alzheimer; ASD: trastorno del espectro autista; AUC: área bajo la curva; ROC: característica operativa del receptor; FPR: tasa de predicción falsa.

las características más informativas. Alickovic et al. (2018) desarrolló un modelo automatizado para detectar y predecir Predicción del inicio de las convulsiones, aplicando ANN, KNN, SVM, y algoritmos RF ML para datos de Friburgo y CHB-MIT. conjuntos (Shoeb, 2009; Ihle et al., 2012). El modelo presentado diferenció con éxito entre interictal, EEG preictales e ictales con una precisión del 99,77%. En un estudio realizado por Li Y et al. (2019), se generó inicialmente una imagen de tiempo-frecuencia de alta resolución utilizando la función de base radial multiescala (MRBF). Optimización de enjambre de partículas modificadas (MPSO) - ortogonal Algoritmo de mínimos cuadrados (OLS). A partir de cada imagen de subbanda, se obtiene una matriz de coocurrencia de niveles de gris (GLCM). Se extrajeron los scriptores y el vector Fisher (FV). Antes de ser ingresados al clasificador SVM, los datos de dimensión... La reducción de la calidad se realizó utilizando la herramienta estadística t-test. La efectividad del método propuesto fue Se evaluó utilizando los conjuntos de datos de Bonn y Hauz Khas, y los resultados demostraron su capacidad para difundir con precisión Diferenciar entre señales ictales y actividad cerebral sana. lazos (Andrzejak et al., 2001; Swami et al., 2016). Cómo Sin embargo, el marco propuesto utilizó un solo canal.

Machine Translated by Google



Tabla 1 Resumen del diagnóstico de epilepsia basado en electroencefalograma (EEG)

| Estudio | Base de datos | Clasificador/detector | Actuación |
|---|---|---|---|
| Alickovic et al., 2018 Kiral- | Friburgo, CHB-MIT Cook | ANN, KNN, SVM, RF | 99,77% de precisión, |
| Kornek et al., 2018 Antoniades | et al., 2013 | MLP | 69% de sensibilidad, |
| et al., 2018 Acharya et al., | Local | CNN | 68% de precisión, |
| 2018b | Bonn | CNN | 88,67% de precisión, 90,00% de especificidad, Sensibilidad del 95,00 |
| Truong y otros, 2018 | Friburgo, CHB-MIT, Kaggle | CNN | % Sensibilidad del 81,4 % (Friburgo), 81,2 % (CHB-MIT) y 75,0 % (Kaggle) 0,02– |
| Tsiouris et al., 2018 | CHB-MIT | LST | 0,11 h-1 FPR |
| Hussein et al., 2019 Li | Bonn | LST | 100% de precisión, 100% de sensibilidad, 100% de |
| Y et al., 2019 | Bonn, Hauz Khas | SVM | especificidad 100,00%, 99,30% y 99,30% de |
| Zhang et al., 2020 | CHB-MIT | CNN | precisión 92,2% de sensibilidad, 0,12 |
| Daoud y Bayoumi, 2019 | CHB-MIT | MLP, DCNN, DCNN+ BiLSTM, DCAE+ BiLSTM | h−1 FPR 99,6% de precisión, 0,004 h−1 FPR |
| Emami et al., 2019 | Local | AE | Sensibilidad del 100 |
| Liang et al., 2020 | CHB-MIT | LRCN | %, sensibilidad del 84 %, especificidad del 99 %, precisión del 99 %, FPR de 0,2 h−1 |
| Geng y otros, 2020 | Friburgo | BiLSTM | 98,09 % de sensibilidad/98,69 % de especificidad (basada en segmentos), 96,3 % de sensibilidad/0,24 h−1 FPR (basada en eventos) |
| Savadkoohi et al., 2020 | Bonn | SVM, KNN | Precisión del 100 % (SVM) y del 99,5 % (KNN) |
| Usman et al., 2021 | Universidad de California en el MIT, Kaggle | SVM, CNN, LSTM | Sensibilidad del 96,28 %/especificidad del 95,65 % (CHB-MIT), sensibilidad del 94,2 %/especificidad del 95,8 |
| Shoeibi y otros, 2021b | Bonn | ML/CNN | % (Kaggle) 99,53 % (dos clases) y 98,67 % (varias clases) Precisión |
| Gramacki y Gramacki, 2022 | Local | CNN | 96%–97% de precisión |
| Tveit y otros, 2023 | Local | CNN | 88,3% de precisión |

CHB: Boston Children's Hospital; MIT: Massachusetts Institute of Technology; ANN: red neuronal artificial; KNN: vecino más cercano k; SVM: máquina de vectores de soporte; RF: bosque aleatorio; MLP: perceptrón multicapa; CNN: red neuronal convolucional; LSTM: red de memoria a corto y largo plazo; DCNN: red neuronal convolucional profunda; BiLSTM: LSTM bidireccional; DCAE: autocodificador convolucional profundo; AE: autocodificador; LRCN: red convolucional recurrente a largo plazo; ML: aprendizaje automático; FPR: tasa de predicción falsa.

Segmentos de EEG, que pueden limitar la clasificación óptima. Daoud y Bayoumi (2019) utilizaron un algoritmo de selección de canal para extraer el canal adecuado y reducir la complejidad computacional, lo que hace que el sistema sea adecuado para la aplicación en tiempo real. El autocodificador (AE) es un modelo de aprendizaje automático no supervisado para el cual la entrada es la misma que la salida. Emami et al. (2019) emplearon AE para identificar las convulsiones como ocurrencias anómalas dentro de los datos de EEG intercitales. Los hallazgos indicaron que el error de AE sirvió como una característica viable para detección de convulsiones, logrando una sensibilidad máxima del 100 % para distinguir entre estados convulsivos y no convulsivos. Savadkoohi et al. (2020) emplearon la prueba t y la selección flotante secuencial hacia adelante (SFFS) para determinar las características óptimas y estadísticamente significativas del conjunto de datos de Bonn. Estas características seleccionadas se introdujeron en los clasificadores SVM y KNN. Los resultados demostró una precisión del 99,5% en el dominio del tiempo, mientras que el dominio de la frecuencia y el dominio del tiempo-frecuencia exhibieron la mayor precisión del 100%.

Se ha establecido la viabilidad clínica de la predicción de convulsiones, pero persisten ciertas limitaciones, como la incertidumbre sobre la aparición de convulsiones entre personas con epilepsia. Para abordar esto, se han desarrollado dispositivos portátiles que permiten la monitorización continua. Kiral-Kornek et al. (2018) desarrollaron un sistema automatizado de predicción de convulsiones epilépticas ajustable por el paciente basado en DL e implementaron el sistema en un chip neuromórfico de bajo consumo. Se entrenó un modelo DL utilizando datos iEEG anotados del conjunto de datos de Cook et al. (2013) para distinguir entre señales preictales e intercitales y se implementó en el chip neuromórfico TrueNorth. El sistema permitió un ajuste instantáneo y fácil, lo que significó

Machine Translated by Google



que los pacientes o los médicos podrían priorizar la alta sensibilidad actividad o tiempo de advertencia bajo según diferentes necesidades o circunstancias. El sistema de predicción logró una sensibilidad media del 69% utilizando datos de iEEG. Aunque los datos de iEEG mejoran el entrenamiento de datos debido a su alta relación señal-ruido, el registro invasivo de iEEG es poco práctico. Los datos de EEG del cuero cabelludo representan una alternativa más conveniente.

Para garantizar la adquisición de datos de alta calidad comparables a los de iEEG, Antoniades et al. (2018) propusieron una arquitectura de aprendizaje automático por conjuntos. Este enfoque no mapea linealmente los EEG del cuero cabelludo a los EEG pseudointracraneales, que posteriormente se incorporan a un modelo CNN.

Notablemente, los autores lograron una precisión del 68% al discriminar automáticamente la enfermedad epiléptica intracraneal.

cargas explosivos improvisados (IED). Acharya et al. (2018b) construyeron una arquitectura CNN de 13 capas de profundidad para detectar cargas explosivos improvisados normales.

clases de ictal y convulsión utilizando el conjunto de datos de Bonn y logró una precisión, especificidad y sensibilidad del 88,67 %, 90,00 % y 95,00 %, respectivamente.

Los modelos DL más pequeños y grandes implican una gran cantidad de partes.

ametros, lo que puede suponer una carga computacional adicional. Truong et al. (2018) aplicaron un método simple y sencillo.

Modelo CNN bajo con solo tres bloques convolucionales.

La información de los dominios de frecuencia y tiempo se extrajo utilizando una transformada de Fourier de tiempo corto,

y luego las características optimizadas se generaron automáticamente en un formato similar a una imagen. Este enfoque logró una sensibilidad del 81,4 %, 81,2 % y 75,0 %,

respectivamente, en la clasificación de los segmentos preictales e interictales.

mentos utilizando Friburgo, Boston Children's Hospital (CHB)-Massachusetts Institute of Technology (MIT),

y conjuntos de datos de Kaggle (Brinkmann et al., 2016). Zhang et al. (2020) también utilizaron el conjunto de datos CHB-MIT para las incautaciones.

predicción de la ura, pero se implementó una ampliación de datos.

Se intentó obtener una diversidad de datos para resolver el problema del desequilibrio de prueba. Se adoptó un algoritmo de filtrado espacial para extraer la señal componente que mejor pudiera transducir la actividad cerebral en la predicción de convulsiones.

ción y se utilizó una CNN superficial. Finalmente, el pro

El enfoque propuesto logró una sensibilidad del 92,2% y una tasa de predicción falsa (FPR) de 0,12 $h^{-1}$ .

Las CNN son capaces de extraer características espaciales de los datos de entrada, pero tienden a pasar por alto las características temporales, particularmente en datos de series de tiempo como EEG.

La detección de la epilepsia mediante señales de EEG implica tempo aspectos ral. Para mejorar la precisión de la detección

ción, se han mejorado ciertas arquitecturas DL recurrentes.

Tsiouris et al. (2018) diseñaron un sistema de dos capas Red LSTM para predicción de convulsiones. Tiempo y frecuencia características del dominio de la frecuencia, correlación cruzada entre cambios Se incorporaron al modelo características de teoría de grafos y canales. Se realizó una evaluación en el conjunto de datos CHB-MIT y el resultado mostró un FPR bajo de 0,02–0,11 $h^{-1}$ , dependiendo de la longitud de las ventanas preictales.

En lugar de elegir características manualmente, Hussein et al. (2019) explotaron una red LSTM para aprender representaciones de alto nivel de señales EEG, y se aplicó una capa completamente conectada (FC) para extraer las características EEG más robustas. Probaron el enfoque en el conjunto de datos de Bonn y lograron una precisión de clasificación del 100 %.

Sensibilidad del 100 % y especificidad del 100 % en tareas de dos clases y de múltiples clases utilizando señales de EEG limpias que estaban libres de artefactos y ruido. También evaluaron

Se probó el modelo en señales EEG sin eliminación de artefactos y se logró una precisión de más del 90 % en la clasificación de múltiples clases, lo que demostró su capacidad para ser desclasificado.

En comparación con el procesamiento de dirección de tiempo único de LSTM, el LSTM bidireccional (BiLSTM) podría procesar series de tiempo en ambas direcciones.

Geng et al. (2020) presentaron un algoritmo BiLSTM que podía seleccionar automáticamente características de la matriz de tiempo-frecuencia obtenida por la transformada S y realizar tareas de clasificación.

El sistema planteado se evaluó en el conjunto de datos de Friburgo.

Los resultados mostraron que la clasificación basada en segmentos logró una sensibilidad del 98,09% y una especificidad del 98,69%. La clasificación basada en eventos obtuvo una sensibilidad del 98,09% y una especificidad del 98,69%.

Sensibilidad del 96,3% y FPR de 0,24 $h^{-1}$ .

Sin embargo, debe tenerse en cuenta que el entrenamiento de un modelo DL requiere una cantidad sustancial de datos para su eficacia.

aprendizaje efectivo. Por otro lado, las características artesanales

Las turas son computacionalmente eficientes y adecuadas para im

Implementación. Shoeibi et al. (2021a, 2021b) emplearon características artesanales para los modelos DL. Primero, complementaron

comparó 50 características artesanales diferentes en términos de mejora importancia y complejidad computacional. La mejor característica

Las texturas seleccionadas por el algoritmo de Fisher fueron luego calculadas.

combinado con CNN-AE. El rendimiento de esta aplicación

El método se evaluó utilizando el conjunto de datos de Bonn, que reveló una precisión del 99,53 % en la clasificación de dos clases y del 98,67 % en la clasificación de múltiples clases. Debido a las eficientes capacidades de combinación del método de redes múltiples, Daoud y Bayoumi (2019) introdujeron un método de combinación de redes múltiples.

Modelo sion DL para predicción automática de convulsiones,

donde los EEG sin procesar se introdujeron directamente en los modelos sin ninguna extracción de características manual. Inicialmente,

Machine Translated by Google



Implementaron una arquitectura de autocodificador convolucional profundo (DCAE) para entrenar previamente el front-end del modelo de manera no supervisada. El aprendizaje por transferencia fue Se empleó para mejorar la capacidad de generalización del DCAE. Posteriormente, se incorporó el codificador preentrenado. integrado con una red BiLSTM para clasificación. El conjunto de datos EEG CHB-MIT logró un rendimiento con una precisión del 99,6 % y un FPR de 0,004 h−1 .

Red convolucional recurrente de largo plazo (LRCN) es un modelo espaciotemporal que combina caracterísi tics tanto de CNN como de LSTM. Liang et al. (2020) pro Se planteó un LRCN de 18 capas para realizar la detección automática de convulsiones y la localización de la zona epileptogénica. El modelo se entrenó y evaluó utilizando la base de datos CHB-MIT. El clasificador resultante demostró una sensibilidad Sensibilidad del 84%, especificidad del 99%, precisión del 99%, y un FPR relativamente bajo de 0,2 h−1 Sin embargo, es importante reconocer la limitación potencial de la intensidad computacional y el riesgo de sobreajuste debido a la disponibilidad limitada del conjunto de datos. Para abordar estas preocupaciones, Usman et al. (2021) emplearon el aprendizaje conjunto de múltiples clasificadores, incluidos SVM, CNN, y LSTM. Metaaprendizaje agnóstico de modelos (MAML) Se utilizó el modelo alimentando las probabilidades de salida de cada clasificador para dar la decisión final de si se trataba de un estado preictal o interictal. De esta manera, entrenaron al clasificador con un número menor de ejemplos de entrenamiento sin sobreajuste. El modelo logró una sensibilidad promedio de 96,28% y una especificidad de 95,65% con un tiempo de anticipación promedio de 33 min en el conjunto de datos CHB-MIT y una sensibilidad promedio de 94,2% y una especificidad de 95,8% en el conjunto de datos Kaggle.

Para mejorar la reproducibilidad de diferentes datos: conjuntos, Gramacki y Gramacki (2022) propusieron una combinación Marco completo para la detección de convulsiones basada en EEG utilizando técnicas de DL. También han propuesto un diseño de ventana deslizante para generar datos de entrenamiento completamente equilibrados. Basándose en su código de acceso abierto, los investigadores podrían analizar sus propios conjuntos de datos EEG con sólo modificaciones menores.

Además de distinguir lo anormal de lo normal o identificar la actividad epileptiforme, Tveit et al. (2023) informó sobre un nuevo modelo CNN, un informe organizado y estandarizado basado en computadora de EEG (SCORE)-AI, que podrían clasificar las grabaciones anormales en las categorías principales que eran más relevantes para las decisiones en pacientes que evolucionaron. Entre ellos se encontraban pacientes epileptiformes focales, epileptiforme-generalizado, no epileptiforme-focal y Anormalidades difusas no epileptiformes. El SCORE-AI tuvo un área bajo la curva ROC (característica operativa del receptor) entre 0,89 y 0,96 para las diferentes categorías de anomalías del EEG. Este desempeño fue comparable al consenso de expertos humanos.

### 4.2 Esquizofrenia

La esquizofrenia es un trastorno crónico del desarrollo neurológico con una prevalencia global del 1% (Saha et al., 2005). Si bien el mecanismo subyacente sigue siendo desconocido, Está claro que numerosos estudios han establecido una correlación entre la esquizofrenia y anomalías estructurales y funcionales del cerebro. Los individuos que padecen esquizofrenia suelen presentar una composición heterogénea. Combinación de síntomas psicóticos, incluidas alucinaciones. aciones y delirios, así como alteraciones conductuales y cognitivas. deterioros cognitivos significativos (McCutcheon et al., 2020) La esquizofrenia afecta de manera significativa su vida diaria. El diagnóstico oportuno de la esquizofrenia es esencial para los pacientes, de modo que la industria farmacéutica pueda ayudar a prevenirla. Se pueden utilizar tratamientos biológicos para aliviar los síntomas. Investigaciones recientes han demostrado la importancia El papel de los patrones EEG en la identificación de la esquizofrenia Se han empleado varias técnicas de ML para lograr una clasificación automatizada y precisa.

Además, se ha investigado el potencial de las redes neuronales en el ámbito del diagnóstico de la esquizofrenia (Barros et al., 2021). La Tabla 2 ofrece una descripción general de los estudios realizados sobre el diagnóstico de la esquizofrenia mediante señales de EEG.

Se han introducido numerosos enfoques experimentales para investigar los biomarcadores EEG en la esquizofrenia. Pacientes con frenia. Estudios sobre el diagnóstico de la esquizofrenia. Los investigadores han examinado los componentes del potencial relacionado con eventos (PRE) de los pacientes mediante la recopilación de datos de EEG durante tareas de memoria de trabajo o tareas de procesamiento visual y auditivo, lo que permitió evaluar ación de la respuesta cerebral debido al resultado de características cognitivas sensoriales específicas. Johannesen et al. (2016) Se realizaron grabaciones de EEG mientras los sujetos estaban en comunicación. Completar una tarea de memoria de trabajo de Sternberg (SWMT), que constaba de cuatro etapas de procesamiento: línea base, codificación, retención y recuperación. La utilización de un clasificador SVM dio como resultado una precisión del 87 %. Anteriormente, la gamma frontal en la etapa de codificación fue identificada por SVM como la característica con mayor ponderación. ture, que coincidió bien con los primeros estudios sobre el papel de la banda gamma en la codificación de la memoria. Los investigadores también han reconocido la utilidad potencial de P300 y

Machine Translated by Google



Tabla 2 Resumen del diagnóstico de esquizofrenia basado en el electroencefalograma (EEG)

| Estudiar | Base de datos | Clasificador/detector | Actuación |
|---|---|---|---|
| Johannesen y otros, 2016 | Local | SVM | 87% de precisión |
| Shim y otros, 2016 | Local | SVM | 88,24% de precisión |
| Oh y otros, 2019 | Instituto de Psiquiatría y Neurología en Varsovia, Polonia | CNN | 98,07% y 81,26% exactitud |
| Jahmunah y otros, 2019 | Instituto de Psiquiatría y Neurología en Varsovia, Polonia | SVM-RBF | 92,91% de precisión |
| Devia y otros, 2019 | Local | LDA | 71% de precisión |
| Li FL y otros, 2019 | Local | SVM/LDA | 90,48% de precisión |
| Phang y otros, 2020 | Estado de Moscú Lomonosov Universidad, Rusia | Conectoma multidominio CNN (MDC-CNN) | 91,69% de precisión |
| Goshvarpour y Goshvarpour, 2020 | RepOD | PNN | 100% de precisión |
| Ahmedt-Aristizabal et al., 2021 | Local | CNN-LSTM | 89,98% de precisión |
| Chang y otros, 2021 | Local | SVM/GNN | 81,33% de precisión |
| Yin y otros, 2023 | Local | GCN | 90,01% de precisión |
| Saadatinia y Salimi-Badr, 2024 | Local | CNN | 99,0% de precisión |

SVM: máquina de vectores de soporte; CNN: red neuronal convolucional; RBF: función de base radial; LDA: análisis discriminante lineal; PNN: red neuronal probabilística; LSTM: red de memoria a largo plazo y corto plazo; GNN: red neuronal de grafos; GCN: red convolucional de grafos; RepOD: Repositorio de Datos Abiertos.

negatividad de desajuste (MMN) como biomarcadores para evaluar esquizofrenia, que puede detectarse mediante audición.
Tareas extrañas de la historia. Estas tareas implican la presentación
ción de estímulos desviados poco frecuentes en medio de situaciones de parada frecuentes
Tonos de resonancia magnética. Shim et al. (2016) realizaron un estudio en el que recopilaron datos de EEG mientras los participantes participaban en un paradigma auditivo pasivo.
Combinaron datos de pico P300 de 62 electrodos como características a nivel de sensor con densidad de corriente cortical como características de EEG a nivel de fuente. Al utilizar una clasificación SVM
sificador, pudieron lograr una clasificación precisa
acia del 88,24%. En un estudio separado, Chang et al.
(2021) utilizaron señales MMN de ERP y em
Se empleó SVM para extraer características de la teoría de grafos. Estas características se utilizaron luego para clasificar a los individuos en tres grupos: esquizofrenia de primer episodio, esquizofrenia crónica frenía y control sano. Esta clasificación se aplica
El enfoque se basó en la comprensión del mecanismo neuronal subyacente al daño MMN en diferentes etapas de la esquizofrenia.

Sin embargo, estas tareas a menudo estaban orientadas a objetivos, lo que planteó desafíos para los pacientes con esquizofrenia con deterioro cognitivo y percepción distorsionada.
Para abordar esta cuestión, Devia et al. (2019) em
Se empleó un paradigma visual sencillo y sin tareas para registrar el EEG mientras los participantes veían escenas naturales.
Al examinar la actividad EEG promedio sincronizada con el inicio de las imágenes, los investigadores identificaron
Diferencias identificadas entre pacientes con esquizofrenia y controles sanos. En concreto, los pacientes mostraron una amplitud del ERP occipital disminuida de aproximadamente 500 ms tras la presentación de las imágenes en comparación con el grupo de control. Posteriormente, estas diferencias se emplearon para la categorización de los individuos diagnosticados con esquizofrenia.

La clasificación abarcó tres clasificadores: LDA, un clasificador basado en reglas y una combinación del clasificador de probabilidad posterior.
idad de dos LDA. Cabe destacar que el clasificador basado en la comparación de la probabilidad posterior, el empleo
Los ERP occipitales exhibieron la sensibilidad más notable.
Actividad al 81% y precisión al 71%.

Además, se exploraron metodologías alternativas centradas en datos de EEG en estado de reposo, y se sugirió que estos datos reflejan la actividad neuronal intrínseca.
(Ciprian et al., 2021). Una base de datos disponible públicamente en el Repositorio de Datos Abiertos (RepOD) contiene datos de EEG en estado de reposo con los ojos cerrados (Olejarczyk y Jernajczyk, 2017; Jahmunah et al., 2019). Se evaluaron varios clasificadores, incluidos DT, LDA, KNN, red neuronal probabilística (PNN) y SVM. El clasificador SVM con función de base radial (SVM-RBF) arrojó la mayor precisión del 92,91 %. Con base en el mismo conjunto de datos,

Goshvarpour y Goshvarpour (2020) implementaron una estrategia de fusión a nivel de características para combinar las características extraídas, lo que resultó en una precisión mejorada en comparación con las pilas de características separadas. La clasificación se realizó con PNN para separar las características del EEG de los esquizofrénicos.
Pacientes frénicos y controles sanos.

Machine Translated by Google



Según algunos estudios, la ausencia de elementos relacionados con la tarea en los datos puede dar lugar a una deficiencia de información completa para la discriminación.
Sin embargo, la incorporación de características derivadas tanto de los estados de reposo como de los de tareas puede proporcionar información clara sobre los déficits cerebrales asociados con la esquizofrenia. Inspirados por esta teoría, Li FL et al. (2019) llevaron a cabo un experimento en el que entrenaron clasificadores LDA y SVM utilizando patrones espaciales inherentes de red (SPN) concatenados.
características de los EEG P300 tanto en reposo como en la actividad. Como resultado, lograron una precisión del 90,48 %.

Al examinar el método DL, la mayoría de los estudios han utilizado datos de estado de reposo, ya que permiten la extracción automática de características abstractas y de alto nivel.
turas a partir de datos brutos. Entre los diversos modelos de DL empleados en la detección de la esquizofrenia, CNN se destaca como uno de los más utilizados. Oh et al. (2019) propusieron un modelo CNN de once capas para distinguir a los pacientes con esquizofrenia y obtuvieron una precisión del 81,26% y del 98,07% para las pruebas no basadas en sujetos y las pruebas basadas en sujetos, respectivamente.

Sin embargo, es importante señalar que el objetivo principal del estudio es:
La principal limitación radica en el tamaño limitado de la muestra, que puede no proporcionar un entrenamiento adecuado para un modelo DL.
Phang et al. (2020) utilizaron EEG multicanal como entrenamiento.
datos para ampliar el conjunto de datos. Diseñaron una CNN de connectoma multidominio (MDC-CNN) con un
función de conectividad combinada, que era adecuada para spa
Modelado de proximidad de dominios. El algoritmo superó a las CNN de dominio único utilizando características individuales, logrando
Con una precisión del 91,69 %. Además de ampliar el conjunto de datos, Saadatinia y Salimi-Badr (2024) generaron conjuntos de datos sintéticos para resolver el problema de sobreajuste y datos de entrenamiento limitados.
Utilizaron la generación de Wasserstein.
Red antagónica activa (GAN) con penalización de gradiente
(WGAN-GP) y autocodificador variacional (VAE) para aumentar los datos, con el VAE mejorando la precisión en un 3,0%, alcanzando el 99,0%. Se extrajeron espectrogramas de señales sin procesar para utilizar características de tiempo-frecuencia,
y se seleccionó CNN para el diagnóstico inicial. También emplearon el modelo local interpretable agnóstico ex
Algoritmo de explicación lineal (LIME) para explicar los problemas más importantes.
frecuencias importantes en el proceso de diagnóstico, solucionando así
abordando las cuestiones de confianza.

Sin embargo, es posible que las CNN no adviertan representar adecuadamente la estructura gráfica de la red cerebral funciona. Como resultado, los modelos que generalizan las CNN a gráficos (por ejemplo, GNN y red convolucional de gráficos)
(GCN)) se han explorado. Chang et al. (2021)
Promedio de un modelo GNN para aprender con éxito la topografía estructura lógica de las redes cerebrales, lo que conduce a super mejoras anteriores en la clasificación de pacientes con esquizofrenia y controles sanos. De manera similar, Yin et al. (2023)
Desarrolló un modelo de reconocimiento automático basado en GCN para detectar esquizofrenia utilizando EEG en estado de reposo.
La matriz de características constaba de características de tiempo-frecuencia.
turas de la señal EEG y las características locales de la red cerebral. El resultado mostró que el lóbulo parietal era la región cerebral que más contribuía a la
en relación con la clasificación. También compararon la re-
resultados utilizando otros modelos (CNN-2, CNN-5 y SVM).
La mayor precisión alcanzada por el modelo propuesto en la identificación de pacientes con primer episodio de esquizofrenia fue del 90,01%.

Estudios recientes se han centrado en distinguir entre personas con esquizofrenia y personas sanas.
Sin embargo, se han realizado menos estudios en personas con riesgo de esquizofrenia. La situación es más complicada porque las anomalías cerebrales son menos evidentes.
abolladura entre personas en riesgo. Ahmedt-Aristizabal et al.
(2021) identificaron a niños en riesgo de esquizofrenia explorando varias técnicas de aprendizaje automático y aprendizaje a distancia.
Se seleccionaron señales MMN de niños con antecedentes familiares de esquizofrenia y/o niños que presentan antecedentes de esquizofrenia. En la arquitectura DL propuesta, no solo utilizaron CNN sino que también agregaron capas recurrentes (LSTM). Los resultados mostraron un rendimiento mejorado de la red híbrida 2D-CNN-LSTM con una precisión promedio del 89,98%.

### 4.3 Depresión

La depresión es un trastorno psiquiátrico común.
Según la Organización Mundial de la Salud (OMS),
Alrededor de 340 millones de personas sufren distintos grados de depresión en todo el mundo. Los mecanismos neurológicos
El anismo y el principio patológico de la depresión aún persisten.
Principalmente no está claro. Las personas con depresión tienen síntomas psicóticos graves.
Trastornos psicológicos y emociones negativas.
izado por el dolor, la fatiga, la desesperación e incluso pensamientos suicidas.
También presentan síntomas físicos como dolores de cabeza, estreñimiento, cambios de peso e insomnio (Simon et al., 1999). El criterio diagnóstico internacional más utilizado es el Manual Diagnóstico y Estadístico de los Trastornos Mentales, Quinta Edición (DSM-5),

Establecido por los Estados Unidos (Asociación Estadounidense de Psiquiatría)
ación, 2013). Sin embargo, un cuestionario de este tipo

Machine Translated by Google



Este enfoque es propenso a la subjetividad del médico y del paciente.
Con esto en mente, los estudios han explorado el uso del EEG para
encontrar biomarcadores de depresión que puedan usarse como una
indicación objetiva. Los investigadores también hicieron pruebas
Fortalezas para desarrollar técnicas basadas en ML/DL para la depresión.
Reconocimiento de la sión. En la Tabla 3 se presenta un resumen de los
estudios presentados.

En cuanto a los biomarcadores para detectar la depresión, una re
La visión destaca que algunas características del EEG, como la asimetría
alfa, son prometedoras (Yasin et al., 2021).
Mumtaz et al. (2017) compararon el EEG alfa interhemi-
asimetría esférica entre la depresión mayor
Pacientes con trastorno depresivo mayor (TDM) y controles sanos. Sus hallazgos
Los estudios revelaron que los individuos deprimidos mostraban una mayor
Actividad EEG anterior. Las características más significativas se
seleccionaron entre las características candidatas (computación de potencia).
tación en diferentes bandas de frecuencia y asimetría alfa del EEG) según
un criterio denominado ROC.
Se utilizaron estructuras con pesos sustanciales para entrenar y probar los
modelos de clasificadores, a saber, LR, SVM y NB. Entre estos modelos,
SVM demostró la alta
rendimiento estimado (precisión = 98,4 %, sensibilidad = 96,66 %,
especificidad=100%).

Se han realizado varios estudios utilizando ERP.
Li et al. (2016) realizaron un experimento que incluía una tarea de
observación de expresiones faciales, basándose en datos previos.
Hay varios hallazgos que indican que la depresión puede afectar la capacidad de
reconocer diferentes emociones faciales. Se analizaron las señales de
EEG, centrándose específicamente en las señales theta, alfa,
y bandas de frecuencia beta. Clasificadores múltiples y características
En el análisis se emplearon métodos de selección de textura.
La precisión más alta del 98% se logró mediante la utilización del método
de selección de características Greedy Stepwise (GSW) basado en
características de correlación seleccionadas.
ción y el clasificador KNN para la banda de frecuencia beta. Se ha
establecido que el componente ERP P300 se correlaciona con la depresión
(Mumtaz et al., 2015).
Shim et al. (2019) realizaron un estudio para investigar la posible eficacia
de utilizar las funciones P300
tanto a nivel de sensor como de fuente para la clasificación
ción del trastorno de estrés postraumático (TEPT) y el TDM.
Durante las tareas auditivas de rareza, recolectaron P300
Señales y se extrajeron la amplitud y latencia de P300 como
características a nivel de sensor y la densidad de fuente actual
(CSD) de los componentes de P300 como característica a nivel
de fuente. Se obtuvo una precisión de clasificación del 70,34 %
para la discriminación entre TEPT y TDM.
utilizando un clasificador SVM lineal de dos clases.

Como los métodos de clasificación ML tradicionales requieren
mayores recursos computacionales y procesan más dimensiones de
características, un número cada vez mayor de aplicaciones basadas en DL
Se han propuesto enfoques para clasificar los datos de EEG tanto de
individuos deprimidos como sanos. Li XW et al. (2019) incorporaron
información espacial obtenida

Tabla 3 Resumen del diagnóstico de depresión basado en el electroencefalograma (EEG)

| Estudiar | Conjunto de datos | Clasificador/detector | Actuación |
|---|---|---|---|
| Li y otros, 2016 | Local | ML (Bolsa de basura, bolsa ... | >91% de precisión |
| Mumtaz y otros, 2017 | Local | LR/SVM/NB | 98,4% de precisión |
| Acharya y otros, 2018a | Local | CNN | Precisión del 93,54 %/95,49 % (datos de EEG del hemisferio izquierdo/derecho) |
| Shim y otros, 2019 | Local | SVM | 70,34% de precisión |
| Ay y otros, 2019 | Acharya y otros, 2018a | CNN-LSTM | 99,12% de precisión |
| Li XW y otros, 2019 | Local | CNN y el Servicio de Migración de Estados Unidos (SVM) | 89,02 % (SVM)/84,75 % (CNN) exactitud |
| Shah y otros, 2019 | Local | Red neuronal artificial | 68,18 % (ojos cerrados)/72,13 % (ojos abiertos) precisión |
| Cai y otros, 2020 | Local | KNN/DT/SVM | 86,98% de precisión (KNN) |
| Sharma y otros, 2021 | Departamento de Psicología, Universidad de Arizona, Estados Unidos | CNN-LSTM | 99,10% de precisión |
| Sarkar y otros, 2022 | Kaggle | MLP/CNN/RNN/LSTM/ SVM/LR | 96,50 % de precisión (RNN) |
| Wang y otros, 2022 | Conjunto de datos MODMA, Universidad de Nuevo México, Estados Unidos | CNN | 93,97% de precisión |

ML: aprendizaje automático; BN: BayesNet; SVM: máquina de vectores de soporte; LR: regresión logística; KNN: vecino más cercano; RF: bosque aleatorio; NB: Bayes ingenuo; CNN: red neuronal convolucional; LSTM: red de memoria a corto y largo plazo; SNN: red neuronal de picos; DT: árbol de decisión; MLP: perceptrón multicapa; RNN: red neuronal recurrente; MODMA: conjunto de datos abiertos multimodales para el análisis de trastornos mentales.

Machine Translated by Google



de los casquillos EEG para mejorar el análisis de los rasgos originales
turas, a saber, la densidad espectral de potencia (PSD) en la frecuencia
dominio de la frecuencia y actividad en el dominio del tiempo.
Estas características se transformaron en imágenes que...
Se incluyó información espacial y posteriormente se creó una CNN.
Con frecuencia se emplean para reconocer estas imágenes características.
El método alcanzó una precisión máxima del 84,75%.
Acharya et al. (2018a) emplearon un modelo CNN de 13 capas de profundidad
y lograron una precisión mayor del 95,49 % al analizar las señales de EEG
del hemisferio derecho. Este hallazgo coincide con investigaciones anteriores
que indican una correlación entre la depresión y la actividad aumentada en
el hemisferio derecho. Utilizando el mismo conjunto de datos, Ay et al. (2019)

Mejoró el desempeño de la clasificación por empleo.
El estudio se realizó con un nuevo modelo híbrido que combinaba
arquitecturas CNN y LSTM. Sus hallazgos coinciden con los de estudios
anteriores, que indican un rendimiento superior de las señales de EEG del
hemisferio derecho en comparación con las del hemisferio izquierdo, logrando
una precisión del 99,12 %.
Los modelos antes mencionados implican un importante esfuerzo computacional.
demandas institucionales. Por el contrario, Sharma et al. (2021)
Se propuso un modelo de red neuronal híbrida CNN-LSTM para la detección
de la depresión que presenta una menor complejidad computacional y de
tiempo. La CNN se utilizó en
aprendizaje poral y se utilizó LSTM en el aprendizaje secuencial.
ing. El modelo propuesto arrojó una clasificación precisa
acia del 99,10%. Sarkar et al. (2022) compararon exhaustivamente las
técnicas de DL y ML para el tratamiento de la depresión.
Protección mediante EEG. RNN logró la mayor acción
precisión, alcanzando el 97,50% durante el entrenamiento y el 96,50%
durante las pruebas.

Sin embargo, cabe señalar que lo anterior
Los estudios mencionados emplearon únicamente una única técnica de
reconocimiento de patrones, sin capacidad para actuar.
requieren conocimientos diagnósticos más profundos. La técnica multimodal
ha ganado popularidad en los últimos tiempos debido a su capacidad para
ofrecer información más completa.
información. Li XW et al. (2019) llevaron a cabo un experimento utilizando
una tarea de estímulo facial emocional y extrajeron la PSD y las actividades
originales como características. Adoptaron el aprendizaje conjunto y SVM
para procesar y clasificar estas características, adquiriendo la mejor precisión
del 89,02%. Cai et al. (2020) propusieron una des-

modelo de discriminación de presión que integró datos de EEG de tres
modalidades recopilados durante la fase neutra,
estímulos auditivos negativos y positivos, respectivamente. Se
extrajeron características lineales y no lineales de cada uno de ellos.
modalidad individual, seguida de una fusión a nivel de características
método para combinar linealmente las matrices de características
de las tres modalidades. Se emplearon varios clasificadores ML.
Se emplearon los clasificadores KNN, que obtuvieron la mayor precisión, con
un 86,98 %. Ambos estudios compartieron las limitaciones
ción de muestras de pequeño tamaño. Para abordar este problema, Wang et
al. (2022) emplearon la fusión de datos multicanal y el aumento de recorte.
Estudios previos han demostrado que
Se ha demostrado de forma concluyente la estrecha asociación entre el lóbulo frontal y la depresión, así
como las actividades psicológicas (Shi et al., 2020). Por lo tanto, sólo se han realizado estudios que
demuestran que el lóbulo frontal está estrechamente relacionado con la depresión y las actividades psicológicas.
Se analizaron tres señales de electrodos, concretamente Fp1, Fp2 y Fpz,
que se originan en la sección del lóbulo prefrontal. Se fusionaron las señales
de EEG de 3 canales y se transformaron en imágenes 2D. Este enfoque
mejoró la precisión del diagnóstico de depresión y los efectos de
agrupamiento, al tiempo que se mantuvieron
manteniendo un procesamiento de señales robusto y de baja complejidad.

Además de la utilización de redes neuronales profundas,
trabajo de redes neuronales profundas (DNN), se han empleado algunos
modelos biológicamente realistas, como la red neuronal con picos (SNN). El
modelo SNN está inspirado en la actividad de picos.
idades observadas en el cerebro humano (Maass, 1997).
Sha y col. (2019) emplearon la arquitectura NeuCube SNN.
Arquitectura para analizar datos de un estudio de caso de depresión.
La precisión obtenida fue del 68,18 % para los datos con los ojos cerrados y
del 72,13 % para los datos con los ojos abiertos.
La SNN todavía era inferior al método DL en términos de
precisión, ya que los modelos DL emplean retropropagación para reducir el
error. Los esfuerzos de investigación futuros pueden
Considere extraer características utilizando CNN u otros modelos DL y
posteriormente integrarlos en el marco SNN.
Trabajar para mejorar el rendimiento.

### 4.4 Enfermedad de Parkinson

La EP es un trastorno neurológico progresivo que surge con la pérdida
de neuronas responsables de la producción de
dopamina. Es el segundo neurotransmisor más prevalente.
Trastorno degenerativo que aumenta con la edad después de la EA.
Las personas con EP presentan síntomas como temblores en reposo,
movimientos lentos (bradicinesia) y distensión muscular.
rigidez muscular (Jankovic, 2008). El diagnóstico de EP se basa principalmente
en síntomas motores como defectos del habla o congelamiento de la marcha.
Sin embargo, los estudios de autopsia y neuroimagen indican que la aparición
de síntomas motores
La EP es una manifestación tardía que se produce cuando hay una
degeneración generalizada de las neuronas dopaminérgicas (Beitz, 2014).
Por lo tanto, la identificación temprana de la EP es vital para tratamientos
neuroprotectores efectivos.
La aplicación de técnicas ML/DL en EEG ha revelado

Machine Translated by Google



Otro método para el diagnóstico de la EP con una baja tasa de error, bajo coste y baja invasividad. El resumen de los estudios seleccionados se muestra en la Tabla 4.

La investigación de biomarcadores de EP fiables y cuantitativos derivados del EEG es actualmente un campo de investigación en auge. En la mayoría de los estudios, los registros del EEG
Los datos se obtienen durante el estado de reposo. Chaturvedi et al. (2017) emplearon técnicas de aprendizaje automático para identificar un subconjunto de características a partir de los datos de EEG cuantitativos (QEEG). amperímetros. Calcularon la potencia relativa en diferentes bandas de frecuencia a lo largo de diferentes regiones del cerebro.
Se calcularon las frecuencias dianas y de pico, así como las relaciones alfa/theta. La RF y la contracción absoluta mínima
Se emplearon métodos de operador de selección y edad (LASSO) para la selección de características. Las características extraídas en
indicó que la relación espectral alfa/theta en la región central izquierda podría ser una característica influyente para la discriminación.
Comparación entre pacientes con EP y controles sanos. El método de discriminación logró finalmente una precisión del 78%.

Sin embargo, Shah et al. (2020) creían que la ac
Las señales EEG obtenidas exhibieron características caóticas,
Sin embargo, los trastornos neurodegenerativos como la EP progresan.
resultó en una alteración de la propiedad dinámica.
De acuerdo con esta teoría, eligieron la sincronización de frecuencia beta y el acoplamiento de amplitud de fase (PAC) en las señales de EEG como biorreactores potenciales.
marcadores. Para enfatizar las alteraciones asociadas a la EP en las propiedades dinámicas de los datos del EEG, se utilizó un em
Se empleó la técnica de reconstrucción de estratificación derivada de la teoría del caos en los datos de EEG obtenidos de
Repositorio de pacientes para datos de EEG + herramientas computacionales (PRED+CT) (Cavanagh et al., 2017).

Se ha demostrado que el uso de DL mitiga la necesidad de ingeniería de características. Oh et al. (2020)
Diseñó una arquitectura CNN de 13 capas para clasificar a individuos con EP y sanos, logrando una precisión del 88,25 %, una sensibilidad del 84,71 % y una especificidad del 91,77 %. Khare et al. (2021) implementaron un enfoque de detección automática de EP llamado PD CNN (PDCNNet), donde transformaron señales 1D en gráficos de tiempo-frecuencia 2D. Distribución pseudo Wigner Ville suavizada
Se utilizó el modelo SPWVD para obtener una representación de tiempo y frecuencia a partir de señales de EEG. Luego, los gráficos 2D se introdujeron en una CNN. El modelo logró una precisión del 100 % y del 99,97 % para dos conjuntos de datos públicos, respectivamente.

En el contexto de las técnicas multimodales, la combinación de EEG y electromiografía (EMG)
Se utilizó para detectar el deterioro cognitivo y las afecciones musculares en la EP. Saikia et al. (2019) realizaron un estudio en el que se extrajeron señales de EEG del cerebro frontal y temporal, junto con la actividad muscular.
idades asociadas con la flexión y extensión de la muñeca. ANN
Se emplearon para la clasificación y el resultado mostró que la combinación de características EEG y EMG resultó
con la tasa de clasificación más alta del 98,8%.

Las investigaciones recientes se han centrado en reducir el número de electrodos, ya que los montajes de EEG de alta densidad no se utilizan habitualmente en los hospitales. Suuronen et al. (2023) realizaron una investigación sobre el impacto de la ubicación de los electrodos en el rendimiento de la clasificación.
Utilizaron un algoritmo de búsqueda basado en el presupuesto y

Tabla 4 Resumen del diagnóstico de la enfermedad de Parkinson (EP) basado en el electroencefalograma (EEG)

| Estudiar | Base de datos | Clasificador/detector | Actuación |
|---|---|---|---|
| Chaturvedi y otros, 2017 | Local | MI | 78% de precisión |
| Saikia y otros, 2019 | Local | ANA | Tasa de clasificación del 98,8 % |
| Oh y otros, 2020 | Local | CNN | 88,25% de precisión, 84,71% de sensibilidad, 91,77% de especificidad |
| Shah y otros, 2020 | Repositorio de datos PRED+CT | Red DGH | 99,22% de precisión |
| Khare y otros, 2021 | OpenNeuro, Hospital Universitario Kebangsaan Malasia | CNN | 100% y 99,97% de precisión |
| Lee y otros, 2021 | Local | ML/CRNN | 99,2% de precisión |
| Qiu y otros, 2022 | OpenNeuro, conjunto de datos de Iowa | SVM/MCNN | 0,999 AUC (MCNN) |
| Suuronen y otros, 2023 | Universidad de Turku, Finlandia | MI | 76% de precisión |
| Bdaqli y otros, 2024 | Universidad de California en San Diego | CNN-LSTM | Precisión del 99,51 % (binario) y del 99,75 % (multiclase) |

ML: aprendizaje automático; ANN: red neuronal artificial; CNN: red neuronal convolucional; PRED+CT: repositorio de pacientes para datos de EEG+ herramientas computacionales; DGHNet: red híbrida generada por sistemas dinámicos; CRNN: red neuronal recurrente convolucional; SVM: máquina de vectores de soporte; MCNN: CNN multiescala; AUC: área bajo la curva; UCSD: Universidad de California, San Diego; LSTM: red de memoria a largo plazo.

Machine Translated by Google



Se desarrolló con éxito un método único de selección de características por canal. El resultado demostró que sólo cinco canales ubicados en el frontal derecho, el temporal izquierdo,
y los sitios occipitales de la línea media eran adecuados para detectar realizando PD con una precisión del 76%.

Sin embargo, la mayoría de los participantes en los estudios antes mencionados tomaban medicación, lo que introduce posibles efectos de confusión. Se han realizado varios estudios para clasificar a los pacientes en condiciones de medicación frente a sin medicación. Shah et al.

(2020) propuso una arquitectura DNN denominada dinámica.
Red híbrida generada por sistema ical (DGHNet) para la clasificación de pacientes con EP en medicación vs.
Estados sin medicación. La red tenía una convolución
capa como capa de entrada para extraer características espectrales y una capa LSTM como capa de salida, lo que da como resultado una
acia del 99,22%. En un estudio independiente, Lee et al. (2021)
registraron dos sesiones de EEG durante estados de medicación activa y desactivada, respectivamente. Emplearon un modelo RNN convolucional (CRNN) que consta de CNN y RNN,
que logró una precisión del 99,2% y una exactitud del 98,9%,
y 99,4% de recuerdo en la clasificación de la EP. Además, el modelo propuesto demostró su capacidad para detectar el impacto de la medicación dopaminérgica utilizando información de fase. Las características relacionadas con la fase también se utilizaron en el estudio de Qiu et al. (2022). Implementaron un
análisis de múltiples patrones que incorporó características de PSD y valor bloqueado de fase (PLV) de los datos de EEG.

Los resultados mostraron diferencias significativas en PSD y PLV entre controles sanos y pacientes con EP (incluidos PD_OFF y PD_ON), particularmente dentro de las bandas de frecuencia beta y gamma. Su modelo CNN multiescala (MCNN) propuesto exhibió un desempeño excepcional.

En el trabajo de Bdaqli et al. (2024), se introdujo una nueva arquitectura 1D CNN-LSTM para extraer características destacadas de las señales de EEG. Para la clasificación,
Se utilizaron tres algoritmos y los resultados indicaron que SVM tuvo el mejor desempeño, logrando una alta precisión del 99,51 % en la clasificación binaria y del 99,75 % en la clasificación multiclase. Para mejorar la interpretación del modelo
Se utilizó la incrustación de vecinos estocásticos distribuidos en t (t-SNE) como método de IA explicable (XAI) en la etapa de posprocesamiento.

4.5 Enfermedad de Alzheimer

La EA es la causa más común de demencia y ocupa la séptima posición como causa principal de mortalidad.

Se trata de una enfermedad neurodegenerativa de alta incidencia en personas mayores de 65 años, caracterizada por su progresión oculta y su impacto devastador en la función cognitiva. Las características patológicas comunes de la enfermedad incluyen placas de beta-amiloide, neuritas distróficas asociadas a las placas y ovillos neurofibrilares dentro de las células nerviosas (Vickers et al., 2000). El diagnóstico temprano y preciso

La detección de la EA es crucial para una intervención y un tratamiento oportunos. Estrategias de tratamiento. El diagnóstico de la EA implica una variedad de procedimientos clínicos, que incluyen pruebas neuropsicológicas, evaluación de la función cognitiva, análisis bioquímicos, etc.
sis y las imágenes cerebrales (Bateman et al., 2012). Los biomarcadores del líquido cefalorraquídeo (LCR) más comunes utilizados para el diagnóstico de la EA son la beta amiloide y la tau (Anoop et al., 2010). En las primeras etapas clínicas, la EA a menudo se manifiesta
se presenta como deterioro cognitivo leve (DCL) (Albert et al., 2011), que es una etapa de transición entre la normalidad y la
envejecimiento anormal (NA) y deterioro cognitivo más severo.
Durante esta etapa, los pacientes a menudo presentan alteraciones cognitivas. alteraciones que superan el rendimiento esperado para su edad, manteniendo al mismo tiempo un grado de independencia funcional. El factor distintivo es si el paciente tiene déficits cognitivos específicos más allá de los cambios típicos relacionados con la edad. El diagnóstico preciso de la EA, especialmente

especialmente en la etapa de deterioro cognitivo leve (DCL), plantea un desafío significativo en la detección de la EA. Las técnicas de imágenes cerebrales, como la resonancia magnética funcional (fMRI),
Tomografía computarizada (TC) y tomografía por emisión de positrones.
La tomografía por emisión de positrones (PET) requiere procedimientos exhaustivos y de alto costo. En la última década, el análisis de la señal de EEG ha surgido como un método alternativo debido a sus características no invasivas y rentables.

Los problemas de clasificación para identificar el EEG en pacientes con EA, deterioro cognitivo leve y control sano se pueden clasificar en dos o tres categorías. ML y DL pueden ayudar a identificar el EEG en pacientes con EA, deterioro cognitivo leve y control sano. Aprender con ahínco las representaciones abstractas del EEG para lograr una mejor generalización. En la Tabla 5 se presentan los avances más recientes en el diagnóstico de la EA mediante la integración del EEG y la IA.

Varios trabajos han utilizado la técnica ML para distinguir a los individuos con EA de los sanos. Por ejemplo, Cassani et al. (2017) propusieron un sistema automático de diagnóstico de EA basado en EEG basado en la eliminación automática de artefactos (AAR) y una configuración de EEG de 7 canales.
lo que proporcionó una oportunidad para la portabilidad y la accesibilidad.
Detección de EA factible. Se analizaron datos de EEG de controles sanos y pacientes con EA, incluidos los espectros

Machine Translated by Google



Tabla 5 Resumen del diagnóstico de la enfermedad de Alzheimer (EA) basado en el electroencefalograma (EEG)

| Estudiar | Tamaño del conjunto de datos | Clasificador/detector | Actuación |
|---|---|---|---|
| McBride y otros, 2014 | 15 HC, 16 MCI, 17 AD | SVM | 85,4% de precisión |
| Cassani y otros, 2017 | 85 AC, 99 DC | SVM | Precisión del 91,4 % (20 canales) y del 77,3 % (7 canales) |
| Ieracitano y col., 2019 | 63 HC, 63 MCI, 63 AD | CNN | 89,8% (AD frente a HC) y 83,3% (AD vs. MCI vs. HC) precisión |
| Bi y Wang, 2019 | 4 HC, 4 MCI, 4 AD | CDBM | 95,04% de precisión |
| Tú y otros, 2020 | 17 HC, 35 MCI, 35 AD | GCN | 91,07% de precisión |
| Vecchio y otros, 2020 | 120 AC, 175 DC | SVM | 95% de precisión |
| Alsharabi y otros, 2022 | 35 HC, 31 AD leve, 22 AD moderado | LDA, QDA, SVM, NB, KNN, DT, ELM, ANN, RF | Precisión del 99,98 % (KNN) |
| Rad y otros, 2021 | 17 AC, 10 DC | CNN | Precisión del 97,5 % (etapa de recuperación) y del 99,0 % (etapa de estimulación) |
| Xia y otros, 2023 | 14 HC, 37 MCI, 49 AD | CNN | 97,10% de precisión |
| Dogan y otros, 2023 | 11 AC, 12 DC | KNN | 100% (validación cruzada de diez veces) y 92,01% (validación cruzada LOSO) exactitud |
| Han y otros, 2024 | 21 NA, 29 NCD | SVM | 92,69% de precisión |
| Boudaya y otros, 2024 | 13 MCI, 11 HC | Aprendizaje automático híbrido (SVM, RF, GB) | 93,86% de precisión, 93,87% de sensibilidad, 93,53% de especificidad |

HC: control sano; DCL: deterioro cognitivo leve; NA: envejecimiento normal; SVM: máquina de vectores de soporte; CNN: red neuronal convolucional; CDBM: máquina de Boltzmann profunda convolucional; GCN: red convolucional de grafos; LDA: análisis discriminante lineal; QDA: análisis discriminante cuadrático; NB: Bayes ingenuo; KNN: vecino más cercano k; DT: árbol de decisión; ELM: máquina de aprendizaje extremo; ANN: red neuronal artificial; RF: bosque aleatorio; NCD: trastorno neurocognitivo; ML: aprendizaje automático; GB: refuerzo de gradiente.

potencia, coherencia y modulación de amplitud. Se utilizó SVM como clasificador y el sistema se evaluó en dos conjuntos de datos diferentes, el de 7 canales y el de 20 canales.
conjuntos de datos de canales, con una precisión del 77,3% y el 91,4%, respectivamente. Vecchio et al. (2020) exploraron la clasificación automática del envejecimiento saludable y la EA en función de la conectividad EEG utilizando SVM.
La conectividad se calculó mediante el análisis de la teoría de grafos en 84 regiones de interés (ROI) de los hemisferios izquierdo y derecho. Los resultados ofrecieron una alta precisión.
acy (área bajo la curva (AUC) de 0,97), lo que indica que el análisis de conectividad EEG combinado con la fuente/
Los biomarcadores de conectividad podrían ser un método prometedor para identificar a los pacientes con EA. Además, Alsharabi et al. (2022) desarrollaron un filtro digital elíptico de paso de banda para eliminar la interferencia, seguido de una transformada wavelet discreta (DWT) para extraer las características de la señal EEG.
Se integraron varias funciones en el DWT para permitir capacidades de diagnóstico mejoradas. Se evaluaron nueve métodos de ML para clasificar las características del EEG. Entre ellos,
El clasificador KNN logró la mayor precisión (99,98%).

Los sistemas automáticos tradicionales basados en EEG destinados al diagnóstico temprano de DCL y EA han sido ampliamente utilizados. Ingeniería de características por fases. A diferencia de estudios anteriores, Se exploró un modelo automatizado de detección de AD,
utilizando un gráfico dirigido para la extracción de características de textura local ción a partir de señales EEG (Dogan et al., 2023). El gráfico se construye a partir de un patrón cerebral de primates (PBP)
Derivado de vías neuronales asociadas con el reconocimiento visual de objetos y la respuesta motora. El modelo combinó PBP con una transformación wavelet de factor q ajustable.
Formulario para extracción de características multinivel, logrando una precisión del 100% y 92,01% utilizando el clasificador KNN con validación cruzada diez veces y LOSO, respectivamente.

Además del EEG en reposo, los ERP han demostrado ser prometedores en el diagnóstico de la EA. Un estudio demostró que la amplitud y la latencia del componente P300 varían con la edad y la progresión de la EA después de un estímulo.
(Rad et al., 2021). Este estudio empleó cuatro estados de tarea, a saber, ojos cerrados, ojos abiertos, recuerdo y estimulación.
EEG de laminación. Tres canales (cero frontal (Fz), paráme
El cero etal (Pz) y el cero central (Cz) se utilizaron para
Actividad cerebral medular. Para la clasificación se utilizaron LDA, red neuronal Elman y CNN. Cabe destacar que el canal Pz mostró mejores características, logrando una precisión del 97,5% y 99,0% en las etapas de recuerdo y estimulación.
respectivamente, al emplear CNN para la clasificación.

Las dos categorías son menos complejas que las tres, pero la última es más significativa en términos de
búsqueda. El diagnóstico de deterioro cognitivo leve puede ayudar en la prevención.

Machine Translated by Google



y el tratamiento de la DA. McBride et al. (2014) utilizaron el cuero cabelludo EEG para detectar deterioro cognitivo en adultos mayores, específicamente deterioro cognitivo leve amnésico (DCLa) y EA temprana. Se extrajeron características estructurales y de complejidad y se utilizó el modelo SVM para distinguir entre grupos. La precisión de clasificación más alta del 85,4 % se logró al analizar datos de EEG durante la condición con los ojos cerrados.

Una limitación del estudio fue el pequeño tamaño de las muestras. tamaño de los participantes. Ieracitano et al. (2019) ejemplifican Amplió el conjunto de datos y propuso un método que incluía Implica el análisis de PSD de trazas de EEG y su representación. Las imágenes en escala de grises 2D (imágenes PSD) se pueden convertir en imágenes en escala de grises 2D (imágenes PSD). Se ha diseñado una CNN personalizada para extraer características de estas imágenes PSD para la clasificación binaria y de tres vías. tareas de sificación. La CNN supera a las metodistas tradicionales. ods, logrando una precisión promedio del 89,8% para la clasificación binaria y del 83,3% para la clasificación de tres vías.

Sin embargo, la precisión de la clasificación de tres clases La tarea de clasificación se vio disminuida debido a la mínima distinción ciones observadas en la PSD entre EA y DCL.

Recientemente se ha explorado el aprendizaje multitarea para... abordar el riesgo de sobreajuste de modelos profundos, que a menudo ocurre con tamaños de muestra pequeños. Bi y Wang (2019) Introdujo un enfoque de aprendizaje multitarea utilizando un Maquinaria de Boltzmann de orden superior convolucional criminativa La máquina de Boltzmann profunda (DBM) y sus variantes han demostrado ser una herramienta alternativa potencialmente poderosa para la extracción de características.
Para mejorar aún más el modelo, se introdujo una capa de etiquetas para cerrar la brecha entre el aprendizaje de características y la clasificación. En este estudio, las señales de EEG se transformaron en un formato de imagen 2D para preservar la espaciamiento. estructura inicial, mientras que los canales de color múltiples eran em empleado para representar la dimensión espectral. En definitiva, El modelo clasificó con éxito las imágenes espectrales de EEG en una de tres clases (control sano, deterioro cognitivo leve y EA) con una precisión del 95,04 %. Sin embargo, el proceso de conversión de señales 1D en imágenes requirió un procesamiento de datos complicado y el conjunto de datos era incompleto.

de tamaño suficiente. Para superar el problema de los datos limitados y mejorar la capacidad de generalización de los modelos profundos, Xia et al. (2023) emplearon diapositivas superpuestas. ventanas para ampliar los datos del EEG. También des- firmó una pirámide profunda CNN (DPCNN) para discriminar nate los EEG en estado de reposo de pacientes con EA, deterioro cognitivo leve y controles sanos. El modelo logró una precisión del 97,10 % al clasificar los conjuntos de datos aumentados en tres categorías. categorías de tinte.

Además de utilizar únicamente señales de EEG, You et al. (2020) combinaron datos de marcha y de EEG para lograr la clasificación de la EA. Para ello, planteó un enfoque de red neuronal en cascada de dos pasos. El primer paso implicó la implementación de una red convolucional de gráficos espacio-temporales basada en la atención (AST-GCN) sobre datos de marcha para distinguir entre controles sanos y pacientes. El segundo paso utilizó redes convolucionales espacio-temporales sobre datos de EEG para clasificar a los pacientes como DCL o EA.

Los resultados de la clasificación de tres vías mostraron rendimiento del 91,07% en comparación con otros métodos. Además de las señales registradas, los mapas ómicos también se pueden utilizar para ayudar en el diagnóstico de enfermedades cerebrales. Los investigadores recolectaron muestras fecales y exosomas de orina de adultos mayores con NA y trastornos neurocognitivos (NCD) para identificar firmas multiómicas y rutas metabólicas. formas (Han et al., 2024). SVM logró una precisión del 92,69 %. Capacidad para clasificar los grupos NA y NCD basándose en datos de EEG fusionados y perfiles multiómicos. Boudaya et al. (2024) incorporaron EEG y variabilidad de la frecuencia cardíaca (VFC) para clasificar a los pacientes con deterioro cognitivo leve y al control sano mientras los sujetos realizaban el examen cognitivo. Se propuso un modelo híbrido de ML (SVM, RF y aumento de gradiente (GB)) con un sistema de votación para mejorar la precisión. El modelo híbrido finalmente logró una precisión promedio del 93,86%, una sensibilidad del 93,87%,

y una especificidad del 93,53%.

### 4.6 Accidente cerebrovascular

El accidente cerebrovascular es una enfermedad devastadora y se ha convertido en una de las principales causas de muerte a nivel mundial (Feigin et al., 2014). Existen dos tipos principales de accidentes cerebrovasculares cerebrales: isquémico y hemorrágico. El accidente cerebrovascular isquémico agudo (ACV) es una forma prevalente de infarto cerebral, Representa más del 80% de los casos. Surge de una in interrupción del flujo sanguíneo cerebral (FSC) a un ritmo rápido región específica, lo que resulta en una disminución del oxígeno y los nutrientes. Las consecuencias de un ictus cerebral pueden ser graves, ya que pueden afectar a diversas funciones cognitivas. Funciones motoras, sensoriales y cognitivas. Síntomas comunes Los síntomas incluyen debilidad repentina o entumecimiento en una lado del cuerpo, alteración del habla, alteración de la coordinación Inapetencia, dolor de cabeza intenso y confusión. Prognosis temprana. Es necesaria una mayor vigilancia para mitigar el impacto negativo en los pacientes. La resonancia magnética y la tomografía computarizada son técnicas de diagnóstico habituales. técnicas para el AIS, pero no son adecuadas para el seguimiento a largo plazo. Recientemente, el EEG ha surgido como una técnica prometedora.

Machine Translated by Google



herramienta tanto para el diagnóstico como para el pronóstico del ictus isquémico agudo (Jor Dan, 2004; Foreman y Claassen, 2012). La observación de un aumento en la actividad de ondas lentas (delta) Se ha documentado bien la relación entre la actividad más rápida (alfa/beta) después del accidente cerebrovascular (Finnigan et al., 2016) Aquí recopilamos varios estudios representativos sobre detección de accidentes cerebrovasculares basados en EEG y el resumen se proporciona en la Tabla 6.

Actualmente, existen limitaciones en la detección de accidentes cerebrovasculares. protección mediante EEG, ya que la mayoría de los conjuntos de datos fueron ob se mantiene después del inicio del ictus. Sin embargo, el CBF se reperfunde. La estimulación y la restauración pueden cambiar las características del EEG. tics en comparación con la fase hiperaguda del accidente cerebrovascular. La mayoría de los estudios se centraron en investigar el EEG como un método prog Herramienta analítica para identificar la gravedad del dolor post accidente cerebrovascular. pacientes. Dewi et al. (2020) propusieron un método que em Utiliza la PSD de las grabaciones de EEG como entradas y emplea utiliza CNN para la extracción automática de características, que logró una precisión del 97,3% al distinguir entre nor accidente cerebrovascular maligno, leve, moderado y grave. Guntari et al. (2020) propusieron un nuevo enfoque para optimizar los canales de EEG para evaluar a los pacientes que han sufrido un accidente cerebrovascular. algoritmos de combinaciones de canales optimizadas, seguidos de RNN para clasificar las señales en tres categorías: Sin ictus, ictus leve y ictus moderado. El método propuesto demostró una precisión del 90,00 % al utilizar solo 12 canales, superando la precisión del 72,22 % al utilizar todos los canales.

Otros estudios han explorado la viabilidad y utilidad La posibilidad de utilizar sistemas de EEG portátiles y de baja densidad en escenarios sensibles al tiempo, como ambulancias o salas de emergencia para la detección de accidentes cerebrovasculares. Giri et al. (2016) utilizaron EEG de 2 canales (C3 y OZ), junto con electrooculografía de 2 canales. (EOG) canales (EOG izquierdo y EOG derecho) para clasificar los datos de accidentes cerebrovasculares de los controles de salud. Se logró un promedio de Precisión de edad del 86 % utilizando una red neuronal convolucional 1D (1DCNN) con normalización por lotes, que superó a otros clasificadores con una simple exploración de características.

tracción. Qureshi et al. (2018) utilizaron EEG portátiles vicios y ML para la detección de accidentes cerebrovasculares isquémicos. Los datos de EEG se recopilaron de solo seis canales. MLP y boot- Los modelos de correa obtuvieron una precisión del 95 % y un área de curva ROC de 0,85. Wilkinson et al. (2020) diseñaron un modelo de correa Sistema EEG portátil y vadeable que consta de siete electrodos que pueden detectar el accidente cerebrovascular y su gravedad. Investigaron relaciones como la relación delta/alfa (DAR) y la relación (delta+theta)/(alfa+beta) (DTABR), junto con datos del movimiento de la cabeza. Se empleó RF para sub- Diferenciación de grupos. Se pudo distinguir entre ACV moderado/grave y ACV leve/controles con una sensibilidad del 63 %, una especificidad del 86 % y una precisión del 76 %.

La investigación antes mencionada utilizó medidas QEEG. uras como biomarcadores de accidente cerebrovascular, que implican análisis numéricos El espectro de la señal EEG también se utilizó como característica de evaluación para evaluar el grado de deterioro motor. deterioro cognitivo en pacientes con accidente cerebrovascular. Li et al. (2014) Se llevaron a cabo tareas cognitivas que involucraban la memoria de trabajo para recopilar datos ERP, en las que a los participantes se les presentó una secuencia aleatoria de números de 4 dígitos en un monitor. itor y encargado de determinar si un dígito específico es apropiado apareció en la pantalla (tarea de retroceso 0) o si el número actual se había mostrado previamente (tarea de retroceso 1). Los controles de salud y los pacientes con accidente cerebrovascular podrían clasificarse utilizando el algoritmo de aprendizaje de núcleo múltiple (MKL)-SVM. ritmo con más del 89% de precisión para la tarea de 0 atrás y 80% de precisión para la tarea de 1 atrás.

Tabla 6 Resumen del diagnóstico de accidente cerebrovascular basado en electroencefalograma (EEG)

| Estudiar | Tipo de detección | Clasificador/detector | Actuación |
|---|---|---|---|
| Li y otros, 2014 | Ataque | MKL-SVM | Precisión del 89 % (0-back) y del 80 % (1-back) |
| Giri y otros, 2016 | Ataque | CNN | 86% de precisión |
| Qureshi y otros, 2018 | Ataque | MLP | 95% de precisión |
| Li y otros, 2020 | Accidente cerebrovascular isquémico/hemorrágico | SVM, DT, RF | 98,51% de precisión |
| Wilkinson y otros, 2020 | Tipo de accidente cerebrovascular/gravedad del accidente cerebrovascular | [illegible] | 76% de precisión |
| Dewi y otros, 2020 | Tipo de accidente cerebrovascular/gravedad del accidente cerebrovascular | CNN | 97,3% de precisión |
| Guntari y otros, 2020 | Tipo de accidente cerebrovascular/gravedad del accidente cerebrovascular | RNN | 90,00% de precisión |
| Singh y otros, 2024 | Tipo de accidente cerebrovascular/gravedad del accidente cerebrovascular/ arteria afectada | FCNN | 97,74 % de precisión (tipo de trazo)/2,1955 RMSE (gravedad del accidente cerebrovascular)/ 95,7 % de precisión (arteria afectada) |

MKL: aprendizaje de núcleos múltiples; SVM: máquina de vectores de soporte; CNN: red neuronal convolucional; MLP: perceptrón multicapa; DT: árbol de decisión; RF: bosque aleatorio; RNN: red neuronal recurrente; FCNN: red neuronal totalmente conectada; RMSE: error cuadrático medio.

Machine Translated by Google



Además de la detección del accidente cerebrovascular y su gravedad, También se ha realizado una búsqueda sobre la clasificación del accidente cerebrovascular isquémico y del accidente cerebrovascular hemorrágico. Li et al. (2020) presentó un nuevo método para clasificar las señales de EEG obtenidas de pacientes con accidente cerebrovascular e infarto cerebral. farcción y hemorragia cerebral. Se introdujo un método de extracción de características basado en la característica de fusión de la energía del paquete wavelet y la característica de entropía jerárquica.
Se emplearon SVM, DT y RF como clasificación.
Los resultados mostraron que la RF que utiliza el método de fusión propuesto logró la mejor precisión del 98,51%.
Singh et al. (2024) propusieron una herramienta de diagnóstico que podría obtener rápidamente información sobre múltiples accidentes cerebrovasculares. Datos de EEG de un minuto. Tres diferentes totalmente controlados
Se definieron modelos de redes neuronales conectadas (FCNN) desarrollado para cada tarea: clasificación del tipo de accidente cerebrovascular, iden tificar la arteria afectada y evaluar la severidad del accidente cerebrovascular. Los modelos lograron resultados impresionantes, incluida una precisión del 97,74 % para la clasificación del tipo de accidente cerebrovascular, un error cuadrático medio (RMSE) de 2,1955 para la evaluación de la gravedad del accidente cerebrovascular y una precisión del 95,7 % para identificar la arteria afectada.

### 4.7 Trastorno del espectro autista

El TEA es un trastorno complejo del desarrollo neurológico. ción caracterizada por trastornos en la interacción social y la comunicación, junto con síntomas restringidos o repetitivos. conductas agresivas (Lord et al., 2018). La etiología de su aparición aún no se ha dilucidado por completo, pero se postula que Se cree que es el resultado de una combinación de factores genéticos y ambientales. Factores mentales que afectan el desarrollo cerebral. TEA Se denomina trastorno del espectro porque manifiesta una amplia gama de síntomas que varían mucho entre individuos.
La asociación entre la epilepsia y el TEA se ha reconocido debido a la mayor prevalencia de epilepsia entre las personas con TEA (Amiet et al., 2008). El protocolo más común utilizado para diagnosticar el TEA implica una evaluación conductual cualitativa realizada por expertos siguiendo criterios establecidos internacionalmente. Criterios establecidos como el DSM-5. La intervención temprana y las terapias para la conducta y el habla son cruciales para mejorar las habilidades de comunicación y la calidad de vida general de las personas con TEA. Algunas investigaciones han demostrado que indicó un patrón de EEG de perfil en forma de U de pacientes con TEA, donde la actividad de las bandas de alta frecuencia (beta y gamma) y las bandas de baja frecuencia (delta y theta) aumenta anormalmente, y la actividad en las bandas medias
Las frecuencias de dle parecen reducidas (Wang et al., 2013). El resumen de los estudios relacionados se presenta en la Tabla 7.

La entropía multiescala (MSE) está diseñada para diferenciar: Entender varios niveles de complejidad e información dentro de una señal biológica. Bosl et al. (2011) utilizaron MSE modificado derivado de datos de EEG en estado de reposo para distinguir entre niños con un desarrollo normal y aquellos que tenían un alto riesgo de autismo (HRA) según los diagnósticos de TEA de sus hermanos mayores. Se empleó un algoritmo SVM multiclase para la clasificación dentro de los diferentes diferentes grupos de edad (6 a 24 meses). Los lactantes fueron clasificados Se identificó con más del 80% de precisión en los grupos de control y HRA a los nueve meses de edad. Esta investigación indicó que la complejidad del EEG podría ser un biomarcador potencial para el TEA en edades muy tempranas antes del inicio de los síntomas.
toms. Sin embargo, los niños con alto riesgo no necesariamente

Tabla 7 Resumen del diagnóstico del trastorno del espectro autista (TEA) basado en el electroencefalograma (EEG)

| Estudiar | Tipo de detección | Clasificador/detector | Actuación |
|---|---|---|---|
| Bosl y otros, 2011 | [illegible] | SVM | Más del 80% de precisión |
| Jamal y otros, 2014 | TEA | SVM | 94,7% de precisión |
| Grossi y otros, 2017 | TEA | MI | 92,8 % de precisión (RF) |
| Bosl y otros, 2018 | LRC frente a HRA frente a ASD | SVM | 99% de especificidad, 82% de sensibilidad, 97% de valores predictivos positivos (bebés de tres meses) |
| Ibrahim y otros, 2018 | Epilepsia vs. TEA vs. normalidad | ANN, KNN, SVM, LDA | 94,6% de precisión |
| Thapaliya y otros, 2018 | TEA | Nota: LR | 100% de precisión |
| Abdolzadegan y otros, 2020 | TEA | SVM | 99,91% de sensibilidad, 90,57% de precisión |
| Bouallegue y otros, 2020 | TEA | CNN | 99,5% de precisión |
| Abou-Abbas y otros, 2021 | HRA sin TEA vs. HRA con TEA | SVM, KNN | 88,44% de precisión |
| Magboo y Magboo, 2022 | TEA | SVM, LR, AdaBoost | Precisión del 99% al 100% |

HRA: alto riesgo de autismo; SVM: máquina de vectores de soporte; ML: aprendizaje automático; RF: bosque aleatorio; LRC: control de bajo riesgo; ANN: red neuronal artificial; KNN: k-vecino más cercano; LDA: análisis discriminante lineal; NB: Bayes ingenuo; LR: regresión logística; CNN: red neuronal convolucional.

Machine Translated by Google



Los niños con un desarrollo normal también pueden presentar problemas de desarrollo más adelante. Grossi et al. (2017) recopilaron datos de EEG de un grupo de 15 niños. niños con TEA comprobado y 10 comprobados típicamente desarrollan niños que están en edad de trabajar. También introdujeron un programa avanzado de Algoritmo de procesamiento llamado organización clasificada en múltiples escalas. Mapa de aprendizaje acoplado con una función implícita como algoritmo de tiempo de compresión (MS-ROM/I-FAST), que extrae características de los datos de EEG sin preprocesamiento. Los resultados mostraron una precisión constante del 100 % en la distinción de casos autistas utilizando varios sistemas de aprendizaje automático en un protocolo de prueba de entrenamiento. El protocolo Leave One Out arrojó la precisión más alta del 92,8 % utilizando el clasificador RF.

Sin embargo, debido a la limitación del pequeño tamaño de la muestra, no fue suficiente para derivar conclusiones definitivas. Posteriormente, Bosl et al. (2018) mejoraron sus previsiones. Estudio exhaustivo ampliando el periodo de medición del EEG. Se recogieron datos de EEG de 99 bebés con hermanos con riesgo de TEA (alto riesgo) y 89 controles de bajo riesgo de entre 3 y 36 meses de edad. Luego, los participantes fueron clasificados en tres grupos de resultados: control de bajo riesgo (LRC): bebés del grupo de bajo riesgo sin TEA; HRA: lactantes del grupo de alto riesgo sin TEA; TEA: lactantes de cualquiera de los grupos que recibieron un diagnóstico de TEA. La clasificación y la predicción se calcularon utilizando el SVM, que logró una precisión de 100 µg/dl. Diagnóstico de TEA o no TEA desde la edad de tres meses, con alta especificidad (99%), sen sensibilidad (82%) y valores predictivos positivos (97%).

Sin embargo, registrar señales de EEG precisas de niños autistas inquietos es un desafío. Las grabaciones se toman durante el sueño con medicación, que pueden alterar el EEG y complicar el análisis. Abdolzadegan et al. (2020) introdujeron un nuevo protocolo para registrar EEG sin sedación, así como extraer datos. características responsables. El EEG se adquirió durante la reproducción de un video de dibujos animados y la agrupación espacial basada en la densidad de los datos Se utilizaron técnicas de duplicación con ruido (DBSCAN) para eliminar los artefactos. Los clasificadores SVM lograron una clasificación Precisión del 90,57 % y una sensibilidad notablemente alta del 99,91 %. Además de centrarse únicamente en el EEG, Thapaliya et al. (2018) combinaron datos de EEG y seguimiento ocular para identificar el TEA. La recuperación de datos se realizó mientras se veían videoclips. Se emplearon varios clasificadores ML y se obtuvo una precisión del 100 % utilizando clasificadores NB y LR.

Los estudios han investigado las alteraciones en la percepción de las emociones en el TEA utilizando ERP registrados en respuesta a diferentes estímulos faciales. Jamal et al. (2014) extrajeron Señales de EEG durante tareas de procesamiento facial cuando se presentaron tres tipos de estímulos faciales emocionales, en Incluyendo expresiones faciales temerosas, neutrales y felices. Se utilizaron parámetros de red complejos como características. turas, y se utilizó SVM como clasificador; los re La búsqueda logró una precisión del 94,7 %. Abou-Abbas et al. (2021) exploraron los ERP visuales y el ML para clasificar a los bebés de alto riesgo que luego desarrollaron TEA. Los datos de ERP se recopilaron de bebés que reaccionaban a los cambios de dirección de la mirada en los rostros (Elsabbagh et al., 2012). Utilizaron la técnica de descomposición modal empírica (EMD) para descomponer los ERP en un conjunto de funciones modal intrínsecas.

Las características extraídas a través de IMF se introdujeron en SVM y KNN para la clasificación. La precisión más alta que alcanzó el estudio fue del 88,44 % utilizando SVM.

Ibrahim y cols. (2018) investigaron la clasificación de EEG Técnicas de diagnóstico automatizado para la epilepsia y el TEA nosis. DWT y correlación cruzada (medición de sincro Se utilizaron métodos de aprendizaje automático (ML) para extraer características del segmento EEG. Se utilizaron para la clasificación, entre ellos ANN, KNN, SVM y LDA. El conjunto de datos de TEA fue proporcionado por la Universidad Rey Abdulaziz (KAU) en Arabia Saudita con diez controles normales y nueve pacientes con TEA (Alhaddad et al., 2012). El estudio finalmente obtuvo una precisión general del 94,6 % en la clasificación de tres clases.

Problema de catión (normal vs. epilepsia vs. autismo). Basándose en el mismo conjunto de datos, Bouallegue et al. (2020) propusieron un enfoque que implica un proceso de DL. Utilizaron filtros de respuesta de impulso finito (FIR) y de respuesta de impulso infinito (IIR) con una RNN de unidad recurrente cerrada (GRU) para preprocesar subbandas informativas, seguidas de in Análisis de componentes dependientes (ICA). CNN fue em empleado en la clasificación. El sistema alcanzó un ac Precisión del 99,5 % para el diagnóstico del autismo. Magboo y Magboo (2022) aplicaron varios modelos de aprendizaje automático, incluidos SVM, LR y AdaBoost, a un conjunto de datos de TEA infantil disponible públicamente. Los mejores modelos pudieron lograr una precisión del 99 % al 100 %. El algoritmo LIME proporcionó modelos experimentales. claridad, ayudando a los médicos a comprender las predicciones del modelo.

## 5 Discusión

### 5.1 Tipos de conjuntos de datos de EEG y desafíos en el diagnóstico de enfermedades cerebrales

Se deben tener en cuenta diferentes tipos de señales EEG, incluido el EEG en estado de reposo y el ERP.

Machine Translated by Google



Dependiendo de la enfermedad, es importante determinar qué tipo de biomarcador de una señal de EEG es el más informativo para una situación determinada. Por ejemplo,
En la detección de la esquizofrenia, se utilizaron ERP como el componente MMN para estudiar los déficits de procesamiento auditivo en individuos (Shim et al., 2016; Chang et al.,
2021). El componente P300 se utilizó con frecuencia para investigar las funciones cognitivas y de memoria en individuos
individuos con depresión y EA (Shim et al., 2019;
Rad et al., 2021). Mayor actividad EEG anterior, par
En particular, la asimetría alfa del EEG y la banda de frecuencia beta han demostrado ser prometedoras para la detección de la depresión (Li et al., 2016; Mumtaz et al., 2017). En el contexto del diagnóstico de la EP, la relación espectral alfa/theta, las alteraciones en la sincronización de la frecuencia beta y el PAC se han destacado como posibles biomarcadores (Chaturvedi et al.,

2017; Shah et al., 2020). Además, la relación tiempo-frecuencia
Los gráficos de señales de EEG también se han utilizado como biomarcadores de EEG. Algunos estudios han convertido con éxito señales de EEG 1D en imágenes de características 2D, una transformación
ción que ha mejorado la aplicabilidad de modelos basados en imágenes como CNN y GNN (Truong et al.,
2018; Bi y Wang, 2019; Ieracitano et al., 2019; Li XW y otros, 2019; Li Y et al., 2019; Khare y otros, 2021;
Wang et al., 2022). Este avance permite la captura de patrones tanto espaciales como jerárquicos.
Sin embargo, al mismo tiempo se debe considerar la intensidad computacional para lograr un equilibrio entre una representación mejorada y un procesamiento eficiente.

Al diseñar la arquitectura del modelo de detección, se deben tener en cuenta tanto el tamaño como las características del conjunto de datos, ya que la IA se basa en métodos impulsados por datos. Los conjuntos de datos en la mayoría de los estudios albergan
datado con un número relativamente pequeño de participantes, lo que puede conducir a una falta de generalización y plantear limitaciones.
ciones al traducirlas en utilidades clínicas. Las soluciones incluyen la ampliación de datos, como la aplicación de transformaciones
aciones a señales EEG o utilizando GAN para crear sincronismos
datos estadísticos, que pueden ampliar el conjunto de datos y mejorar la solidez del modelo (Zhang et al., 2020; Wang et al.,
2022; Saadatinia y Salimi-Badr, 2024). El aprendizaje por transferencia, que utiliza un modelo entrenado previamente en un conjunto de datos relevante más grande y lo ajusta en un conjunto de datos objetivo más pequeño, también es útil para resolver problemas de sobreajuste (Daoud y Bayoumi, 2019).
Las técnicas, como la deserción y la regularización de peso, también pueden ayudar a prevenir el sobreajuste al garantizar modelos más simples que se generalicen mejor. Las plataformas de intercambio de datos también pueden
Se establecerá un diálogo entre los investigadores para crear conjuntos de datos más grandes y diversos.

En algunas enfermedades mentales, como la depresión, los pacientes...
Los pacientes que participaron en la prueba estaban bajo medicación,
y los posibles efectos de confusión de la medicación psicotrópica pueden no estar controlados. Incluso cuando los participantes
Se les pide a los pantalones que estén libres de medicamentos por un tiempo. Antes de realizar un registro de EEG, no se puede descartar por completo el efecto de la medicación. Los estudios podrían explorar estrategias
Estrategias para minimizar las variables de confusión o realizar investigaciones para evaluar el impacto de medicamentos psicotrópicos específicos en el EEG (Shah et al., 2020; Lee et al.,
(2021; Qiu y col., 2022).

La mayoría de los trabajos publicados sobre trastornos cerebrales basados en EEG
El diagnóstico de la facilidad se basaba generalmente en configuraciones de EEG que variaban entre 16, 20, 32, 64 y 128 electrodos.
En este sentido, sería ventajoso centrarse en la adquisición de datos con un número reducido de electrodos, lo que permitiría
permitiendo el desarrollo de dispositivos EEG portátiles capaces de Capacidad de realizar grabaciones a largo plazo en entornos cotidianos.

### 5.2 Avances y desafíos de los modelos de IA

Antes de la llegada del aprendizaje automático, se utilizaban muchos análisis de los dominios estadístico, temporal, de frecuencia o de tiempo-frecuencia en varios algoritmos de aprendizaje automático convencionales. Comparar el rendimiento de clasificación logrado por diferentes diseños de arquitectura en diversas enfermedades cerebrales y conjuntos de datos de EEG plantea desafíos, pero la complejidad de las señales de EEG dificulta la obtención de resultados verdaderamente espectaculares. La implementación de DL se destaca por tener varias ventajas. En primer lugar, los modelos de DL pueden lograr una comprensión más profunda de los datos debido a su capacidad de aprender representaciones jerárquicas directamente de los datos sin procesar. Este aprendizaje jerárquico permite la extracción de características complejas y abstractas que podrían ser difíciles de identificar utilizando métodos de ML tradicionales.

En segundo lugar, los modelos DL facilitan la selección automática de funciones.
ción, reduciendo la dependencia de características creadas a mano y conocimiento específico del dominio. Además, los algoritmos híbridos, como CNN-LSTM o CNN-AE, tienden a superar a otros algoritmos individuales en experimentos de ablación (Ay et al., 2019; Daoud y Bayoumi,

2019; Liang y otros, 2020; Ahmedt-Aristizabal et al.,
2021; Sharma et al., 2021). Sin embargo, uno de los problemas
El problema de los modelos DL es su interpretabilidad limitada;
porque implican operaciones matemáticas complejas.
En ocasiones, a los médicos les puede resultar difícil confiar y

Machine Translated by Google



Adoptar modelos DL para el análisis de datos de EEG en contextos médicos. Esto se puede mejorar mediante el desarrollo de desarrollo de técnicas como mecanismos de atención o el uso de métodos XAI.

Una limitación para determinar el mejor modelo es la base de datos utilizada. Los conjuntos de datos locales pueden introducir sesgos. Debido a diversos factores, como la edad y el género, la potencial afectando sustancialmente los resultados informados. Por el contrario, el uso de bases de datos de acceso abierto hace que la investigación sea más comparativa. capaz y ayuda a identificar los mejores métodos. Por ejemplo, En la investigación sobre la detección de la esquizofrenia, los estudios de Oh et al. (2019) y Jahmunah et al. (2019) utilizaron el mismo conjunto de datos del Instituto de Psiquiatría y Neurología. ogy en Varsovia, Polonia. Sus resultados demostraron que el modelo CNN superó al modelo SVM tradicional. Sin embargo, incluso los estudios que utilizan el mismo modelo y conjunto de datos pueden arrojar resultados diferentes debido a pequeñas diferencias en los parámetros y métodos de procesamiento de datos. Por ejemplo, en la investigación sobre detección de convulsiones, Acharya et al. (2018b) y Shoeibi et al. (2021b) propusieron modelos CNN basados en el mismo conjunto de datos, pero lograron diferentes niveles de rendimiento. En el futuro, se deben realizar esfuerzos para estandarizar los informes de IA. tecnologías con métodos estandarizados para su descripción ing y medición de resultados (Sounderajah et al., 2021).

En general, una alta precisión suele ir acompañada de una baja especificidad en comparación con la recuperación y la precisión, destacando... El desafío de lograr una precisión relativa es el siguiente: Tradicionalmente, los modelos DL, como las CNN y los LSTM, son cada vez más favorecidos por su capacidad de extraer y aprender automáticamente características complejas de datos de alta dimensión. Las CNN extraen automáticamente características espaciales de los datos de EEG y son eficientes en el intercambio de parámetros. Los LSTM pueden capturar detecciones temporales a largo plazo. dependencias en las señales de EEG y aliviar los problemas de gradiente de desaparición. Los modelos de ML tradicionales como SVMs principal valor, especialmente cuando se combina con características hechas a mano y se utiliza en enfoques de conjunto.

La integración de metodologías avanzadas impulsadas por IA en el diagnóstico y el tratamiento de enfermedades cerebrales también es muy prometedora para mejorar el diagnóstico. precisión métrica y mejora de los resultados del paciente. Al aprovechar el procesamiento del lenguaje natural (PLN) y modelos de lenguaje de gran tamaño como el transformador generativo preentrenado de chat (ChatGPT), los médicos pueden examinar las notas clínicas en busca de factores de riesgo y sugerir posibles diagnósticos. facilitando así una intervención más temprana. Además, la exploración futura de técnicas de diagnóstico basadas en la web Tiene el potencial de mejorar la eficiencia de los sistemas CAD. Los modelos preentrenados se pueden implementar en base a la computación en la nube, lo que reduce la carga computacional en los sistemas locales y permite que los profesionales de la salud... también para recibir resultados de manera oportuna.

### 5.3 Potencial del EEG multimodal y neurológico datos fisiológicos

La exploración del EEG multimodal tiene potencial importante para el futuro. Por ejemplo, la cooperación simultánea La recopilación de datos de EEG y EOG o de seguimiento ocular nos ayuda a comprender cómo se reflejan la atención y el procesamiento visual tanto en la actividad cerebral como en el movimiento ocular (Giri et al., 2016; Thapaliya et al., 2018). Los datos de EMG y de marcha brindan información sobre las condiciones motoras de los pacientes con EP y EA (Saikia et al., 2019; You et al., 2020). La EMG también puede ayudar a eliminar los artefactos musculares en los datos del EEG. Se ha indicado que se pueden observar cambios en los registros de frecuencia cardíaca a corto plazo durante un estado preictal de convulsión (Moridani y Farhadi, 2017).

Sin embargo, el EEG tiene sus propias ventajas y desventajas. Ventajas. Por ejemplo, si bien el EEG no es invasivo y es relativamente económico y proporciona datos de la actividad cerebral en tiempo real, tiene una resolución espacial limitada. en comparación con modalidades de imagen como la resonancia magnética. Además, El EEG es sensible al ruido y a los artefactos, lo que puede complicar la interpretación de los datos. Además de los datos del EEG, Combinando múltiples fuentes de datos, como informes médicos. Los datos ómicos, los estudios de imágenes y los cables pueden proporcionar una visión integral del estado de un paciente. Al combinar los datos de EEG y MRI, es posible capturar información completa sobre la actividad y la estructura cerebral, considerando simultáneamente los aspectos espaciales y temporales. La HRV se puede combinar además con los registros de EEG para mejorar los métodos de predicción de la epilepsia. ya que HRV ofrece información valiosa sobre el automóvil. funcionamiento del sistema nervioso autónomo, reflejando el equilibrio entre las actividades simpáticas y parasimpáticas. En el diagnóstico de enfermedades cerebrales complejas como la EA, la EP y la esquizofrenia, los datos ómicos proporcionan una visión integral de los mecanismos moleculares que subyacen a la función y la enfermedad cerebral. Al explorar la interacción entre las oscilaciones neuronales y las moléculas, Al combinar las vías de señalización, los médicos pueden descubrir biomarcadores que sean más específicos e informativos. Las investigaciones futuras pueden investigar técnicas innovadoras para fusionar la información. ción desde diferentes modalidades, ofreciendo así una visión más

Machine Translated by Google



Una comprensión integral de las enfermedades cerebrales,
Contribuyendo a una mayor precisión diagnóstica y a una mayor personalización.
Estrategias terapéuticas armonizadas. Fusionar diferentes modalidades
Se pueden explorar varios enfoques. Por ejemplo,
Por ejemplo, los métodos DL, como las redes neuronales multimodales y los
mecanismos de atención, integran dinámicamente múltiples
Fuentes de datos de varios tipos. Métodos basados en gráficos, como GNN,
modelar las interacciones entre modalidades, mientras que el canon
El análisis de correlación cuantitativa (CCA) encuentra patrones compartidos entre ellos.

## 6 Conclusiones

En este artículo se presenta una revisión del diagnóstico de enfermedades cerebrales basado en EEG con un enfoque en la tecnología de IA. La IA ha demostrado ser muy prometedora en el diagnóstico de enfermedades cerebrales mediante señales de EEG. Mediante el aprovechamiento de las señales utilizando tanto técnicas tradicionales de ML como técnicas avanzadas de DL, Los sistemas de IA pueden mejorar la precisión del diagnóstico y ofrecer información sobre trastornos cerebrales complejos. Los estudios Visto resalta la efectividad de varios modelos de IA, como SVM y CNN, y modelos híbridos, como CNN-LSTM, para clasificar y predecir afecciones como epilepsia, esquizofrenia, depresión, EP, EA, accidente cerebrovascular y TEA. Las consideraciones clave incluyen la selección del tipo de señal de EEG más informativo para enfermedades específicas, el equilibrio entre una mejor representación y eficiencia computacional, y la necesidad de conjuntos de datos más grandes y equilibrados para mejorar la generalización. La investigación futura debería integrar múltiples datos modales, incluidos otros tipos de EEG, como EOG y EMG, o combinar EEG con otras imágenes cerebrales técnicas de envejecimiento, como la resonancia magnética y la variabilidad del ritmo cardíaco, para proporcionar una comprensión más completa de las enfermedades cerebrales. Además, mejorar la interpretabilidad de los modelos DL y explorar sistemas de diagnóstico basados en la web utilizando modelos previamente entrenados en plataformas en la nube podría mejorar aún más la eficiencia y la accesibilidad de las herramientas de diagnóstico impulsadas por IA.

## Expresiones de gratitud

Este trabajo fue financiado por el Proyecto Nacional Clave de Investigación y Desarrollo de China (No. 2021ZD0200405) y la Fundación Nacional de Ciencias Naturales de China (Números. 62271443, 32250008 y 82330064).

## Contribuciones del autor

Ping WANG, Liujing ZHUANG y Hong ZHANG de firmó el manuscrito. Shunuo SHANG escribió el manuscrito. Yingqian SHI completó el dibujo de todas las figuras. Yajie ZHANG y Mengxue LIU revisaron el artículo. Todos los autores leyeron y aprobaron la versión final.

## Cumplimiento de las normas éticas

Liujing ZHUANG es miembro del Comité de Jóvenes Científicos. ber para Revista de la Universidad de Zhejiang-SCIENCE B (Biomedi Cine y Biotecnología) y no participó en la revisión editorial ni en la decisión de publicar este artículo. Shunuo SHANG, Yingqian SHI, Yajie ZHANG, Mengxue LIU, Hong ZHANG, Ping WANG y Liujing ZHUANG declaran que no tienen ningún conflicto de intereses.

Esta revisión no contiene ningún estudio con sujetos humanos o animales realizado por ninguno de los autores.

## Referencias

Abdolzadegan D, Moattar MH, Ghoshuni M, 2020. Un método robusto para el diagnóstico temprano del trastorno del espectro autista a partir de señales de EEG basado en la selección de características y el método DBSCAN. Biocybern Biomed Eng, 40(1):482-493. https://doi.org/10.1016/j.bbe.2020.01.008

Abou-Abbas L, van Noordt S, Desjardins JA, et al., 2021. Uso de la descomposición modal empírica en el análisis ERP para clasificar el riesgo familiar y los resultados diagnósticos del trastorno del espectro autista. Brain Sci, 11(4):409. https://doi.org/10.3390/brainsci11040409

Acharya UR, Oh SL, Hagiwara Y, et al., 2018a. Detección automatizada de la depresión basada en EEG mediante convolución profunda Red neuronal artificial. Programas de métodos computacionales Biomédicos 161:103-113. https://doi.org/10.1016/j.cmpb.2018.04.012

Acharya UR, Oh SL, Hagiwara Y, et al., 2018b. Conversaciones profundas Red neuronal funcional para la detección automatizada y Diagnóstico de convulsiones mediante señales de EEG. Comput Biol Med, 100:270-278. https://doi.org/10.1016/j.compbiomed.2017.09.017

Ahmedt-Aristizabal D, Fernando T, Denman S, et al., 2021. Identificación de niños en riesgo de esquizofrenia mediante aprendizaje profundo y respuestas EEG. IEEE J Biomed Health Inform, 25(1):69-76. https://doi.org/10.1109/JBHI.2020.2984238

Albert MS, Dekosky ST, Dickson D, et al., 2011. El diagnóstico Síndrome de deterioro cognitivo leve debido a la enfermedad de Alzheimer. facilidad: Recomendaciones del Instituto Nacional sobre Grupos de trabajo de la Asociación de Alzheimer y Envejecimiento sobre pautas de diagnóstico para la enfermedad de Alzheimer. Demencia por Alzheimer, 7(3):270-279. https://doi.org/10.1016/j.jalz.2011.03.008

Alhaddad MJ, Kamel MI, Malibary HM, et al., 2012. Diagnóstico Análisis discriminante lineal FLDA de Fisher para autismo mediante EEG. Int J Bio-Sci Bio-Technol, 4(2):45-54.

Alickovic E, Kevric J, Subasi A, 2018. Evaluación del desempeño ación de la descomposición de modos empíricos, la transformada wavelet discreta y la descomposición empaquetada wavelet para la automatización. Detección y predicción de ataques epilépticos acoplados. Biomed

Machine Translated by Google



Control de procesos de señal, 39:94-102.
https://doi.org/10.1016/j.bspc.2017.07.022

Alsharabi K, Salamah YB, Abdurraqeeb AM, et al., 2022.
Procesamiento de señales de EEG para trastornos de Alzheimer utilizando transformadas wavelet discretas y enfoques de aprendizaje automático.
Acceso IEEE, 10:89781-89797.
https://doi.org/10.1109/ACCESS.2022.3198988

Asociación Estadounidense de Psiquiatría, 2013. Diagnóstico y estadísticas
Manual clínico de los trastornos mentales, quinta edición.
puede Psychiatric Publishing, Washington, EE.UU.
https://doi.org/10.1176/appi.books.9780890425596

Amiet C, Gourfinkel-An I, Bouzamondo A, et al., 2008. Epi
La lepsia en el autismo se asocia con discapacidad intelectual y género: evidencia de un metanálisis. Biol Psych
iatría, 64(7):577-582.
https://doi.org/10.1016/j.biopsych.2008.04.030

Andrzejak RG, Lehnertz K, Mormann F, et al., 2001. Indica
ciones de ecuaciones deterministas no lineales y de dimensión finita
Estructuras en series temporales de actividad eléctrica cerebral: de
Dependencia de la región de registro y del estado cerebral. Phys Rev E, 64(6):061907.
https://doi.org/10.1103/PhysRevE.64.061907

Anoop A, Singh PK, Jacob RS, et al., 2010. Biomarcadores del LCR para el diagnóstico de la enfermedad de Alzheimer. Int J Alzheimers Dis, 2010:606802.
https://doi.org/10.4061/2010/606802

Antoniades A, Spyrou L, Martin-Lopez D, et al., 2018. Arquitecturas neuronales profundas para mapear el cuero cabelludo con el EEG intracraneal. Int J Neur Syst, 28(8):1850009.
https://doi.org/10.1142/S0129065718500090

Ay B, Yildirim O, Talo M, et al., 2019. Detección automatizada de depresión mediante representación profunda y aprendizaje de secuencias.
ing con señales EEG. J Med Syst, 43:205.
https://doi.org/10.1007/s10916-019-1345-y

Barros C, Silva CA, Pinheiro AP, 2021. Enfoques avanzados de aprendizaje basados en EEG para predecir la esquizofrenia: promesas y dificultades.
Artif Intell Med, 114:102039.
https://doi.org/10.1016/j.artmed.2021.102039

Bateman RJ, Xiong CJ, Benzinger TLS, et al., 2012. Cambios clínicos y de biomarcadores en la enfermedad de Alzheimer de herencia dominante. N Engl J Med, 367(9):795-804.
https://doi.org/10.1056/NEJMoa1202753

Bdaqli M, Shoeibi A, Moridian P, et al., 2024. Diagnóstico de la enfermedad de Parkinson a partir de señales de EEG utilizando un modelo CNN-LSTM e IA explicable. En: Ferrández Vicente JM, Val Calvo M, Adeli H (Eds.), Inteligencia artificial para neurología
Ciencia y sistemas emocionales. IWINAC 2024. Conferencia
Notas en Ciencias de la Computación, Vol. 14674. Springer, Cham.
https://doi.org/10.1007/978-3-031-61140-7_13

Beitz JM, 2014. Enfermedad de Parkinson: una revisión. Front Biosci, 6(1):65-74.
https://doi.org/10.2741/s415

Bi XJ, Wang HB, 2019. Diagnóstico temprano de la enfermedad de Alzheimer basado en imágenes espectrales de EEG utilizando aprendizaje profundo.
Red Racional, 114:119-135.
https://doi.org/10.1016/j.neunet.2019.02.005

Bosl W, Tierney A, Tager-Flusberg H, et al., 2011. EEG com
La complejidad como biomarcador del riesgo de trastorno del espectro autista.
Revista Médica BMC, 9:18.
https://doi.org/10.1186/1741-7015-9-18

Bosl WJ, Tager-Flusberg H, Nelson CA, 2018. Análisis de EEG para la detección temprana del trastorno del espectro autista: un enfoque basado en datos.
Sci Rep, 8:6828.
https://doi.org/10.1038/s41598-018-24318-x

Bouallegue G, Djemal R, Alshebeili SA, et al., 2020. Un dy
Enfoque basado en aprendizaje profundo de filtrado dinámico DF-RNN para el diagnóstico de trastornos neurológicos basado en EEG. IEEE Access, 8:206992-207007.
https://doi.org/10.1109/ACCESS.2020.3037995

Boudaya A, Chaabene S, Bouaziz B, et al., 2024. Cognición leve
Detección de deterioro cognitivo basado en datos de EEG y HRV.
Proceso de señal digital, 147:104399.
https://doi.org/10.1016/j.dsp.2024.104399

Brenner RP, Reynolds CF III, Ulrich RF, 1988. Efectos diagnósticos
Eficacia del análisis EEG espectral computarizado versus visual
sis en sujetos ancianos normales, dementes y deprimidos.
Electroencefalograma Clin Neurophysiol, 69(2):110-117.
https://doi.org/10.1016/0013-4694(88)90206-4

Brinkmann BH, Wagenaar J, Abbot D, et al., 2016. Crowd
Pronóstico reproducible de convulsiones en la epilepsia humana y canina.
Brain, 139(6):1713-1722.
https://doi.org/10.1093/brain/aww045

Cai HS, Qu ZD, Li Z, et al., 2020. Aplicaciones de fusión a nivel de características
Enfoques basados en datos de EEG multimodales para el reconocimiento de la depresión. Inf Fusion, 59:127-138.
https://doi.org/10.1016/j.inffus.2020.01.008

Cassani R, Falk TH, Fraga FJ, et al., 2017. Hacia un diagnóstico automatizado de la enfermedad de Alzheimer basado en electroencefalografía
nosis utilizando dispositivos portátiles de baja densidad. Biomed Signal Process Control, 33:261-271.
https://doi.org/10.1016/j.bspc.2016.12.009

Cavanagh JF, Napolitano A, Wu C, et al., 2017. El repositorio de pacientes para datos de EEG + herramientas computacionales (PRED+CT).
Frente Neuroinform, 11:67.
https://doi.org/10.3389/fninf.2017.00067

Chang Q, Li CC, Tian Q, et al., 2021. Clasificación de la esquizofrenia de primer episodio, la esquizofrenia crónica y el control sano según la red cerebral de negatividad de desajustes mediante red neuronal gráfica. IEEE Trans Neural Syst Rehabil
Eng, 29:1784-1794.
https://doi.org/10.1109/TNSRE.2021.3105669

Chaturvedi M, Hatz F, Gschwandtner U, et al., 2017. Quanti
Las mediciones de EEG cuantitativas (EEG cuantitativas) diferencian a los pacientes con enfermedad de Parkinson (EP) de los controles sanos (HC).
Front Aging Neurosci, 9:3.
https://doi.org/10.3389/fnagi.2017.00003

Ciprian C, Masychev K, Ravan M, et al., 2021. Diagnóstico de esquizofrenia mediante conectividad efectiva de datos de EEG en estado de reposo.
Algorithms, 14(5):139.
https://doi.org/10.3390/a14050139

Cook MJ, O'Brien TJ, Berkovic SF, et al., 2013. Predicción de la probabilidad de convulsiones con un dispositivo implantado a largo plazo para convulsiones.

Machine Translated by Google



Sistema de asesoramiento en pacientes con epilepsia farmacorresistente: Un estudio realizado por primera vez en humanos. Lancet Neurol, 12(6):563-571. https://doi.org/10.1016/s1474-4422(13)70075-9

Daoud H, Bayoumi MA, 2019. Convulsiones epilépticas eficientes antes y después de la terapia. Dicción basada en aprendizaje profundo. IEEE Trans Biomed Cir Cuits Syst, 13(5):804-813. https://doi.org/10.1109/TBCAS.2019.2929053

Devia C, Mayol-Troncoso R, Parrini J, et al., 2019. Clase de EEG sificación durante la visualización libre de escenas para la detección de esquizofrenia. IEEE Trans Neural Syst Rehabil Eng, 27(6): 1193-1199. https://doi.org/10.1109/TNSRE.2019.2913799

Dewi FY, Faza A, Prajitno P, et al., 2020. Clasificación de gravedad del accidente cerebrovascular sificación basada en señales EEG utilizando red neuronal convolucional 1D. J Phys Conf Ser, 1528:012006. https://doi.org/10.1088/1742-6596/1528/1/012006

Dogan S, Baygin M, Tasci B, et al., 2023. Modelo automatizado de detección de la enfermedad de Alzheimer basado en patrones cerebrales de primates utilizando señales EEG. Cogn Neurodyn, 17(3):647-659. https://doi.org/10.1007/s11571-022-09859-2

Elsabbagh M, Mercure E, Hudry K, et al., 2012. La sensibilidad neuronal infantil a la mirada dinámica se asocia con el autismo emergente posterior. Curr Biol, 22(4):338-342. https://doi.org/10.1016/j.cub.2011.12.056

Emami A, Kunii N, Matsuo T, et al., 2019. Autocodificación del electroencefalograma del cuero cabelludo a largo plazo para detectar ataques epilépticos como sistema de apoyo al diagnóstico. Comput Biol Med, 110:227-233. https://doi.org/10.1016/j.compbiomed.2019.05.025

Feigin VL, Forouzanfar MH, Krishnamurthi R, et al., 2014. Carga mundial y regional de accidentes cerebrovasculares durante 1990-2010: Resultados del estudio sobre la carga mundial de enfermedad de 2010. Revista Lanceta, 383(9913):245-255. https://doi.org/10.1016/S0140-6736(13)61953-4

Ferree TC, Luu P, Russell GS, et al., 2001. Impedancia de los electrodos del cuero cabelludo, riesgo de infección y calidad de los datos del EEG. Clin Neurophysiol, 112(3):536-544. https://doi.org/10.1016/S1388-2457(00)00533-2

Finnigan S, Wong A, Read S, 2016. Definición de actividad EEG lenta anormal en el accidente cerebrovascular isquémico agudo: relación delta/alfa como índice QEEG óptimo. Clin Neurophysiol, 127(2): 1452-1459. https://doi.org/10.1016/j.clinph.2015.07.014

Foreman B, Claassen J, 2012. EEG cuantitativo para la detección ción de la isquemia cerebral. Crit Care, 16:216. https://doi.org/10.1186/cc11230

Geng MX, Zhou WD, Liu GY, et al., 2020. Detección de convulsiones epilépticas basada en la transformada de Stockwell y la respuesta bidireccional. memoria a corto plazo y a largo plazo. IEEE Trans Neural Syst Rehabil Eng, 28(3):573-580. https://doi.org/10.1109/TNSRE.2020.2966290

Giri EP, Fanany MI, Arymurthy AM, et al., 2016. Identificación de accidente cerebrovascular isquémico basada en EEG y EOG utilizando una red neuronal convolucional de identificación y normalización por lotes. Conferencia internacional sobre informática avanzada y sistemas de información (ICACSIS) de 2016, Malang, Indonesia, págs. 484-491. https://doi.org/10.1109/ICACSIS.2016.7872780

Goodfellow I, Bengio Y, Courville A, 2016. Aprendizaje profundo. Traductores, MIT Press, Cambridge, Massachusetts.

Goshvarpour A, Goshvarpour A, 2020. Diagnóstico de esquizofrenia sis utiliza esquemas innovadores de fusión a nivel de características de EEG. Física, Ingeniería y Ciencias Médicas, 43(1):227-238. https://doi.org/10.1007/s13246-019-00839-1

Gramacki A, Gramacki J, 2022. Un marco de aprendizaje profundo para la detección de convulsiones epilépticas basado en señales de EEG neonatales. Sci Rep, 12:13010. https://doi.org/10.1038/s41598-022-15830-2

Grossi E, Olivieri C, Buscema M, 2017. Diagnóstico del autismo a través de EEG procesado por algoritmos computacionales avanzados. Ritmos: un estudio piloto. Programas de métodos computacionales Biomed, 142:73-79. https://doi.org/10.1016/j.cmpb.2017.02.002

Guntari EW, Djamal EC, Nugraha F, et al., 2020. Clasificación Análisis de la señal EEG post-ictus mediante algoritmos genéticos y redes neuronales recurrentes. 2020 7º Congreso Internacional Conferencia sobre ingeniería eléctrica, informática y ciencias de la computación (EECSI), Yogyakarta, Indonesia, p.156-161. https://doi.org/10.23919/EECSI50503.2020.9251296

Han Y, Zeng XL, Hua L, et al., 2024. La fusión del perfil multiómico y los datos de EEG multimodales contribuye a la estrategia de diagnóstico personalizada para los trastornos neurocognitivos. Microbiome, 12:12. https://doi.org/10.1186/s40168-023-01717-5

Hoole P, Pirapaharan K, Basar SA, et al., 2012. Autismo, EEG e investigación electromagnética cerebral. Conferencia IEEE-EMBS 2012 sobre ingeniería y ciencias biomédicas, Langkawi, Malasia, páginas 541-543. https://doi.org/10.1109/IECBES.2012.6498036

Huang DD, Qian K, Fei DY, et al., 2012. Electroencefaloga Interfaz cerebro-computadora basada en electroencefalografía (EEG): un control de silla de ruedas virtual en 2D basado en eventos sincronización/sincronización y control de estado. IEEE Trans Neural Syst Rehabil Eng, 20(3):379-388. https://doi.org/10.1109/TNSRE.2012.2190299

Hussein R, Palangi H, Ward RK, et al., 2019. Arquitectura de red neuronal profunda optimizada para la detección robusta de epi- convulsiones lépticas mediante señales de EEG. Clin Neurophysiol, 130(1):25-37. https://doi.org/10.1016/j.clinph.2018.10.010

Ibrahim S, Djemal R, Alsuwailem A, 2018. Electroencefalograma Procesamiento de señales electroencefalográficas (EEG) para la epilepsia y la autóloga. Diagnóstico de los trastornos del espectro autista. Biocybern Biomed Eng, 38(1):16-26. https://doi.org/10.1016/j.bbe.2017.08.006

Ieracitano C, Mammone N, Bramanti A, et al., 2019. A Con Enfoque de redes neuronales evolutivas para la clasificación de las etapas de la demencia basado en la representación espectral 2D de registros de EEG. Neurocomputing, 323:96-107. https://doi.org/10.1016/j.neucom.2018.09.071

Ihle M, Feldwisch-Drentrup H, Teixeira CA, et al., 2012.

Machine Translated by Google



EPILEPSIAE—Una base de datos europea sobre epilepsia. Comput Methods Programs Biomed, 106(3):127-138. https://doi.org/10.1016/j.cmpb.2010.08.011

Jahmunah V, Oh SL, Rajinikanth V, et al., 2019. Detección automatizada de esquizofrenia mediante procesamiento de señales no lineal. Métodos de procesamiento. Artif Intell Med, 100:101698. https://doi.org/10.1016/j.artmed.2019.07.006

Jamal W, Das S, Oprescu IA, et al., 2014. Clasificación de aut Trastorno del espectro autista mediante aprendizaje supervisado de medidas de conectividad cerebral extraídas de sincroestados. J Neural Eng, 11(4):046019. https://doi.org/10.1088/1741-2560/11/4/046019

Jankovic J, 2008. Enfermedad de Parkinson: características clínicas y diagnóstico. nos. J Neurol Neurosurg Psychiatry, 79(4):368-376. https://doi.org/10.1136/jnnp.2007.131045

Jemal I, Mitiche A, Mezghani N, 2021. Un estudio de las características del EEG complejidad de la predicción de ataques epilépticos. Appl Sci, 11(4):1579. https://doi.org/10.3390/app11041579

Johannesen JK, Bi JB, Jiang RH, et al., 2016. Aprendizaje automático. Identificación de características del EEG que predicen el rendimiento de la memoria de trabajo en esquizofrenia y adultos sanos. Neuropsiquiatría y electrofisiología, 2:3. https://doi.org/10.1186/s40810-016-0017-0

Jordan KG, 2004. EEG de emergencia y monitorización continua de EEG. Toring en el accidente cerebrovascular isquémico agudo. J Clin Neurophysiol, 21(5):341-352. https://doi.org/10.1097/01.WNP.0000145005.59766.D2

Khare SK, Bajaj V, Acharya UR, 2021. PDCNNet: una red de computadoras autónomas Marco matemático para la detección de la enfermedad de Parkinson utilizando señales EEG. IEEE Sensors J, 21(15):17017-17024. https://doi.org/10.1109/JSEN.2021.3080135

Kiral-Kornek I, Roy S, Nurse E, et al., 2018. Predicción de convulsiones epilépticas utilizando big data y aprendizaje profundo: hacia un sistema móvil. eBioMedicine, 27:103-111. https://doi.org/10.1016/j.ebiom.2017.11.032

Krook-Magnuson E, Soltesz I, 2015. Más allá del martillo y el bisturí: control selectivo de circuitos para las epilepsias. Nat Neurociencia, 18(3):331-338. https://doi.org/10.1038/nn.3943

Kwak NS, Müller KR, Lee SW, 2015. Un exoesqueleto de miembros inferiores. Sistema de control de Eton basado en potenciales evocados visuales de estado estable. J Neural Eng, 12(5):056009. https://doi.org/10.1088/1741-2560/12/5/056009

LeCun Y, Bengio Y, Hinton G, 2015. Aprendizaje profundo. Naturaleza, 521(7553):436-444. https://doi.org/10.1038/nature14539

Lee S, Hussein R, Ward R, et al., 2021. Un enfoque de red neuronal convolucional-recurrente para la clasificación EEG en estado de reposo en la enfermedad de Parkinson. J Neurosci Methods, 361:109282. https://doi.org/10.1016/j.jneumeth.2021.109282

Li FL, Wang JJ, Liao YY, et al., 2019. Diferenciación de la esquizofrenia mediante la combinación de la red cerebral EEG espacial Patrones de trabajo de descanso y tarea P300. IEEE Trans Neural Syst Rehabil Eng, 27(4):594-602. https://doi.org/10.1109/TNSRE.2019.2900725

Li FL, Fan YZ, Zhang XY, et al., 2020. Método de fusión de múltiples características basado en la señal EEG y su aplicación en la clasificación de accidentes cerebrovasculares. J Med Syst, 44:39. https://doi.org/10.1007/s10916-019-1517-9

Li XO, Chen X, Yan YN, et al., 2014. Clasificación de señales de EEG utilizando una máquina de vectores de soporte de aprendizaje de núcleo múltiple. Sensors, 14(7):12784-12802. https://doi.org/10.3390/s140712784

Li XW, Hu B, Sun ST, et al., 2016. Depresión leve basada en EEG Detección selectiva mediante métodos de selección de características y clasificación. fiers. Programas de métodos computacionales Biomed, 136:151-161. https://doi.org/10.1016/j.cmpb.2016.08.010

Li XW, Zhang X, Zhu J, et al., 2019. Reconocimiento de la depresión mediante métodos de aprendizaje automático con diferentes estrategias de generación de características. Artif Intell Med, 99:101696. https://doi.org/10.1016/j.artmed.2019.07.004

Li Y, Cui WG, Huang H, et al., 2019. Detección de convulsiones epilépticas ción en señales EEG utilizando redes de función de base radial multiescala dispersas y el enfoque vectorial de Fisher. Knowl-Based Syst, 164:96-106. https://doi.org/10.1016/j.knosys.2018.10.029

Liang WX, Pei HJ, Cai QL, et al., 2020. EEG epiléptico del cuero cabelludo Reconocimiento y localización de zonas génicas basado en redes convolucionales recurrentes de largo plazo. Neurocomputación, 396:569-576. https://doi.org/10.1016/j.neucom.2018.10.108

Lord C, Elsabbagh M, Baird G, et al., 2018. Trastorno del espectro autista. Lancet, 392(10146):508-520. https://doi.org/10.1016/S0140-6736(18)31129-2

Lotte F, Faller J, Guger C, et al., 2012. Combinación de BCI con realidad virtual: hacia nuevas aplicaciones y una BCI mejorada. En: Allison BZ, Dunne S, Leeb R, et al. (Eds.), To Interfaces cerebro-computadora prácticas. Física biológica y médica, Ingeniería biomédica. Springer, Berlín, Heidelberg, p.197-220. https://doi.org/10.1007/978-3-642-29746-5_10

Maass W, 1997. Redes de neuronas activas: la tercera generación ación de modelos de redes neuronales. Neural Netw, 10(9): 1659-1671. https://doi.org/10.1016/S0893-6080(97)00011-7

Magboo MSA, Magboo VPC, 2022. IA explicable para la automatización Clasificación de los ismos en niños. En: Jezic G, Chen-Burger YHJ, Kusek M, et al. (Eds.), Agentes y sistemas multiagente: tecnologías y aplicaciones 2022. Smart In novación, Sistemas y Tecnologías, Vol. 306. Springer, Singapur, pág.195-205. https://doi.org/10.1007/978-981-19-3359-2_17

Malmivuo J, Plonsey R, 1995. Bioelectromagnetismo: Prin Principios y aplicaciones de los campos bioeléctricos y biomagnéticos. Traductores, Oxford University Press, Nueva York, EE.UU.

McBride JC, Zhao XP, Munro NB, et al., 2014. Análisis espectral y de complejidad de las características del EEG del cuero cabelludo para el deterioro cognitivo leve y la enfermedad de Alzheimer temprana. Programas de métodos computacionales Biomed, 114(2):153-163. https://doi.org/10.1016/j.cmpb.2014.01.019

Machine Translated by Google



McCutcheon RA, Marques TR, Howes OD, 2020. Esquizofrenia
Frenia: una visión general. JAMA Psychiatry, 77(2):201-210.
https://doi.org/10.1001/jamapsychiatry.2019.3360

Mohri M, Rostamizadeh A, Talwalkar A, 2018. Fundamentos del aprendizaje automático, 2.ª edición. Traductores, MIT Press,
Cambridge, Estados Unidos.

Moridani MK, Farhadi H, 2017. Variabilidad de la frecuencia cardíaca como biomarcador para la predicción de crisis epilépticas. Bratisl Lek Listy, 118(1):3-8.
https://doi.org/10.4149/BLL_2017_001

Mota AR, Duarte L, Rodrigues D, et al., 2013. Desarrollo de un electrodo cuasi seco para registro de EEG. Sens Actua
Tors A Phys, 199:310-317.
https://doi.org/10.1016/j.sna.2013.06.013

Mumtaz W, Malik AS, Yasin MAM, et al., 2015. Revisión sobre biomarcadores predictivos de EEG y ERP para la depresión mayor.
Trastorno neurológico. Control de procesos de señales biomédicas, 22:85-98.
https://doi.org/10.1016/j.bspc.2015.07.003

Mumtaz W, Xia LK, Ali SSA, et al., 2017. Electroencefalo
Técnica asistida por computadora basada en electroencefalografía (EEG) para diagnosticar
Trastorno depresivo mayor (TDM) de la nariz. Biomed Signal Process Control, 31:108-115.
https://doi.org/10.1016/j.bspc.2016.07.006

Norcia AM, Appelbaum LG, Ales JM, et al., 2015. El potencial evocado visual de estado estable en la investigación de la visión: una revisión. J Vis, 15(6):4.
https://doi.org/10.1167/15.6.4

Oh SL, Vicnesh J, Ciaccio EJ, et al., 2019. Modelo de red neuronal convolucional profunda para el diagnóstico automatizado de la esquizofrenia.
Frenia mediante señales de EEG. Appl Sci, 9(14):2870.
https://doi.org/10.3390/app9142870

Oh SL, Hagiwara Y, Raghavendra U, et al., 2020. Un enfoque de aprendizaje profundo para el diagnóstico de la enfermedad de Parkinson a partir de señales de EEG. Neural Comput Appl, 32(15):10927-10933.
https://doi.org/10.1007/s00521-018-3689-5

Olejarczyk E, Jernajczyk W, 2017. EEG en la esquizofrenia.
Versión 1.0
https://doi.org/10.18150/repod.0107441

Phang CR, Noman F, Hussain H, et al., 2020. Una red neuronal convolucional de connectoma multidominio para identificar
Detección de esquizofrenia a partir de patrones de conectividad EEG.
IEEE J Biomed Health Inform, 24(5):1333-1343.
https://doi.org/10.1109/JBHI.2019.2941222

Qiu LN, Li JP, Pan JH, 2022. Detección de la enfermedad de Parkinson basada en análisis de patrones múltiples y convolución de múltiples escalas.
Redes neuronales funcionales. Front Neurosci, 16:957-181.
https://doi.org/10.3389/fnins.2022.957181

Qureshi AA, Zhang CX, Zheng R, et al., 2018. Detección de accidente cerebrovascular isquémico mediante señales de EEG. CASCON '18: Pro
Actas de la 28ª Conferencia Internacional Anual sobre Ciencias de la Computación e Ingeniería de Software, págs. 301-308.

Rad EM, Azarnoosh M, Ghoshuni M, et al., 2021. Diagnóstico de la enfermedad de Alzheimer leve mediante señales de EEG y ERP.
ing clasificadores lineales y no lineales. Biomed Signal Pro
Control de Procesos, 70:103049.
https://doi.org/10.1016/j.bspc.2021.103049

Roohi-Azizi M, Azimi L, Heysieattalab S, et al., 2017. Cambios en la actividad bioeléctrica del cerebro en la cognición,
Conciencia y algunos trastornos mentales. Med J Islam Re
Irán público, 31(1):307-312.
https://doi.org/10.14196/mjiri.31.53

Saadatinia M, Salimi-Badr A, 2024. Un método explicable basado en aprendizaje profundo para el diagnóstico de esquizofrenia mediante el uso de datos generativos. IEEE Access, 12:98379-
98392.
https://doi.org/10.1109/ACCESS.2024.3428847

Saha S, Chant D, Welham J, et al., 2005. Una revisión sistemática de la prevalencia de la esquizofrenia. PLoS Med, 2(5):e141.
https://doi.org/10.1371/journal.pmed.0020141

Saikia A, Hussain M, Barua AR, et al., 2019. EEG-EMG cor
Relación con la enfermedad de Parkinson. Int J Eng Adv Technol, 8(6):1179-1185.
https://doi.org/10.35940/ijeat.F8360.088619

Sarkar A, Singh A, Chakraborty R, 2022. Un estudio comparativo basado en aprendizaje profundo para rastrear la depresión mental a partir de datos de EEG. Neurosci Inf, 2(4):100039.
https://doi.org/10.1016/j.neuri.2022.100039

Savadkoohi M, Oladunni T, Thompson L, 2020. Un enfoque de aprendizaje automático para la predicción de ataques epilépticos utilizando la señal de electroencefalograma (EEG). Biocybern Biomed Eng, 40(3):1328-1341.
https://doi.org/10.1016/j.bbe.2020.07.004

Schmidhuber J, 2015. Aprendizaje profundo en redes neuronales: una descripción general. Neural Netw, 61:85-117.
https://doi.org/10.1016/j.neunet.2014.09.003

Shah D, Wang GY, Doborjeh M, et al., 2019. Aprendizaje profundo de datos de EEG en la arquitectura de red neuronal de picos inspirada en el cerebro NeuCube para una mejor comprensión de la desregulación.
pression. En: Gedeon T, Wong K, Lee M (Eds.), Procesamiento de información neuronal. ICONIP 2019. Apuntes de clase en informática, vol. 11955. Springer, Cham, págs. 195-206.
https://doi.org/10.1007/978-3-030-36718-3_17

Shah SAA, Zhang L, Bais A, 2020. Red híbrida profunda compacta basada en sistema dinámico para la clasificación de Par-
Señales de EEG relacionadas con la enfermedad de Kinson. Red neuronal, 130:
75-84.
https://doi.org/10.1016/j.neunet.2020.06.018

Sharma G, Parashar A, Joshi AM, 2021. DepHNN: una nueva red neuronal híbrida para electroencefalogramas (EEG)
cribado basado en la depresión. Biom Signal Process Con
control, 66:102393.
https://doi.org/10.1016/j.bspc.2020.102393

Shi QX, Liu A, Chen RY, et al., 2020. Detección de depresión mediante una señal de EEG de tres canales en estado de reposo. Ingeniería eléctrica y ciencia de sistemas, procesamiento de señales.
arXiv:2002.09175.
https://doi.org/10.48550/arXiv.2002.09175

Shim M, Hwang HJ, Kim DW, et al., 2016. Diagnóstico de esquizofrenia basado en aprendizaje automático utilizando características de EEG combinadas a nivel de sensor y a nivel de fuente. Schizophr Res, 176(2-3):314-319.
https://doi.org/10.1016/j.schres.2016.05.007

Machine Translated by Google



Shim M, Jin MJ, Im CH, et al., 2019. Clasificación basada en aprendizaje automático entre el trastorno de estrés postraumático y el trastorno depresivo mayor utilizando características P300. Neuro Imagen Clin, 24:102001. https://doi.org/10.1016/j.ncl.2019.102001

Shoeb AH, 2009. Aplicación del aprendizaje automático a la detección y el tratamiento de la aparición de crisis epilépticas. Tesis doctoral, Instituto Tecnológico de Massachusetts, Cambridge, Estados Unidos.

Shoeibi A, Ghassemi N, Alizadehsani R, et al., 2021a. Una comparación exhaustiva de funciones creadas a mano y autocodificadores convolucionales para detectar convulsiones epilépticas. ción en señales EEG. Expert Syst Appl, 163:113788. https://doi.org/10.1016/j.eswa.2020.113788

Shoeibi A, Khodatars M, Ghassemi N, et al., 2021b. Detección de convulsiones epilépticas mediante técnicas de aprendizaje profundo: una revisión ver. Int J Environ Res Salud Pública, 18(11):5780. https://doi.org/10.3390/ijerph18115780

Simon GE, Vonkorff M, Piccinelli M, et al., 1999. Un análisis internacional Estudio internacional de la relación entre los síntomas somáticos y la depresión. N Engl J Med, 341(18):1329-1335. https://doi.org/10.1056/NEJM199910283411801

Singh S, Dawar D, Mehmood E, et al., 2024. Determinación de la utilidad diagnóstica del EEG para evaluar la gravedad del accidente cerebrovascular mediante modelos de aprendizaje profundo. Biomed Eng Adv, 7:100121. https://doi.org/10.1016/j.bea.2024.100121

Sounderajah V, Ashrafian H, Golub RM, et al., 2021. Desarrollo Elaboración de una guía de presentación de informes para estudios de precisión de pruebas diagnósticas centrados en inteligencia artificial: el protocolo STARD-AI. Revista de Medicina Interna y Jurídica de España, 11(6):e047709. https://doi.org/10.1136/bmjopen-2020-047709

Suuronen I, Airola A, Pahikkala T, et al., 2023. Clasificación basada en el presupuesto de la enfermedad de Parkinson a partir del EEG en estado de reposo. IEEE J Biomed Health Inform, 27(8):3740-3747. https://doi.org/10.1109/JBHI.2023.3235040

Swami P, Gandhi TK, Panigrahi BK, et al., 2016. Una novela ro Modelo de diagnóstico de busto para detectar convulsiones en electroencefalografía Cefalografía. Expert Syst Appl, 56:116-130. https://doi.org/10.1016/j.eswa.2016.02.040

Thapaliya S, Jayarathna S, Jaime M, 2018. Evaluación del EEG y los movimientos oculares para el trastorno del espectro autista. Conferencia internacional IEEE 2018 sobre Big Data (Big Data), Seattle, WA, EE. UU., págs. 2328-2336. https://doi.org/10.1109/BigData.2018.8622501

Truong ND, Nguyen AD, Kuhlmann L, et al., 2018. Convolu Redes neuronales funcionales para la predicción de convulsiones mediante el uso de redes neuronales intracelulares. Electroencefalograma craneal y del cuero cabelludo. Redes neuronales. 105:104-111. https://doi.org/10.1016/j.neunet.2018.04.018

Tsiouris KM, Pezoulas VC, Zervakis M, et al., 2018. Una red de aprendizaje profundo de memoria a corto y largo plazo para el pre- Detección de convulsiones epilépticas mediante señales de EEG. Comput Biol Med, 99:24-37. https://doi.org/10.1016/j.compbiomed.2018.05.019

Tveit J, Aurlien H, Plis S, et al., 2023. Interpretación automatizada ción de electroencefalogramas clínicos mediante inducción artificial inteligencia. JAMA Neurol, 80(8):805-812. https://doi.org/10.1001/jamaneurol.2023.1645

Usman SM, Khalid S, Bashir S, 2021. Un método de aprendizaje conjunto basado en aprendizaje profundo para predecir convulsiones epilépticas. ción. Comput Biol Med, 136:104710. https://doi.org/10.1016/j.compbiomed.2021.104710

Vecchio F, Miraglia F, Alù F, et al., 2020. Clasificación de la enfermedad de Alzheimer con respecto al envejecimiento fisiológico con biomarcadores de EEG innovadores en una implementación de aprendizaje automático. J Alzheimers Dis, 75(4):1253-1261. https://doi.org/10.3233/JAD-200171

Vickers JC, Dickson TC, Adlard PA, et al., 2000. La causa de la degeneración neuronal en la enfermedad de Alzheimer. Prog Neurobiol, 60(2):139-165. https://doi.org/10.1016/S0301-0082(99)00023-4

Wang BY, Kang YY, Huo DY, et al., 2022. Diagnóstico EEG de depresión basado en fusión de datos multicanal y clip- Aumento de ping y red neuronal convolucional. Frente Fisiol, 13:1029298. https://doi.org/10.3389/fphys.2022.1029298

Wang J, Barstein J, Ethridge LE, et al., 2013. Anormalidades del EEG en estado de reposo en los trastornos del espectro autista. J Neuro dev Disord, 5:24. https://doi.org/10.1186/1866-1955-5-24

Wilkinson CM, Burrell JI, Kuziek JWP, et al., 2020. Predecir Determinación de la gravedad del accidente cerebrovascular con un registro de 3 minutos del sistema de EEG portátil Muse para el diagnóstico rápido del accidente cerebrovascular. Sci Rep, 10:18465. https://doi.org/10.1038/s41598-020-75379-w

Xia W, Zhang R, Zhang X, et al., 2023. Un nuevo método para diagnosticar la enfermedad de Alzheimer utilizando una CNN de pirámide profunda basada en señales de EEG. Heliyon, 9(4):e14858. https://doi.org/10.1016/j.heliyon.2023.e14858

Yasin S, Hussain SA, Aslan S, et al., 2021. Detección del trastorno depresivo mayor y del trastorno bipolar basada en EEG mediante redes neuronales: una revisión. Comput Methods Programs Biomed, 202:106007. https://doi.org/10.1016/j.cmpb.2021.106007

Yin GM, Chang Y, Zhao YL, et al., 2023. Reconocimiento automático Estudio de la esquizofrenia a partir de las características de la red cerebral mediante una red neuronal convolucional gráfica. Asian J Psychiatr, 87:103687. https://doi.org/10.1016/j.ajp.2023.103687

You Z, Zeng RH, Lan XY, et al., 2020. Clasificación de la enfermedad de Alzheimer con una red neuronal en cascada. Publicación principal Salud Pública, 8:584387. https://doi.org/10.3389/fpubh.2020.584387

Yuvaraj R, Murugappan M, Mohamed Ibrahim N, et al., 2014. Sobre el análisis de la potencia, frecuencia y asimetría del EEG en la enfermedad de Parkinson durante la producción de emociones. Procesamiento. Función cerebral del comportamiento, 10:12. https://doi.org/10.1186/1744-9081-10-12

Zhang Y, Guo Y, Yang P, et al., 2020. Predicción de convulsiones de epilepsia ción en EEG utilizando un patrón espacial común y convolución red neuronal artificial. IEEE J Biomed Health Inform, 24(2):465-474. https://doi.org/10.1109/JBHI.2019.2933046